



Pro gradu -tutkielma
Meteorologia

NÄKYVYYSENNUSTEIDEN TUOTTAMINEN ERILAISIN MENETELMIN JA NIIDEN
KESKINÄISEN HYVYYDEN VERTAAMINEN LENTOSÄÄSSÄ

Mari Nikkilä

16.9.2018

Ohjaajat: FT Jussi Ylhäisi, Prof. Heikki Järvinen

Tarkastajat: Prof. Heikki Järvinen, FT Jussi Ylhäisi

HELSINGIN YLIOPISTO
FYSIKAN LAITOS

PL 64 (Gustaf Hällströmin katu 2)
00014 Helsingin yliopisto

Tiedekunta/Osasto – Fakultet/Sektion – Faculty Matemaattis-luonnontieteellinen tiedekunta		Laitos – Institution – Department Fysikaalisten tieteiden laitos	
Tekijä – Författare – Author Mari Nikkilä			
Työn nimi – Arbetets titel – Title Näkyvyysennusteiden tuottaminen erilaisin menetelmin ja niiden keskinäisen hyvyyden vertaaminen lentosäässä			
Oppiaine – Läroämne – Subject Meteorologia			
Työn laji – Arbetets art – Level Pro Gradu	Aika – Datum – Month and year 16.9.2018	Sivumäärä– Sidoantal – Number of pages 46	
<p>Tiivistelmä – Referat – Abstract</p> <p>Lentosääennusteiden laatiminen on yksi tärkeimmistä lennon sujuvuuteen vaikuttavista tekijöistä. Lentosääennusteita laaditaan kolmen tunnin välein lentokentille kuvaamaan merkittävän sään vaihteluita. Suurimmille kentille ennusteita lasketaan aina 24 tunnin päähän, kun taas pienemmille niitä tuotetaan 2-9h päähän tarpeiden mukaan. TAF:eissa yhtenä tärkeimmistä suureista ennustetaan näkyvyyttä, joka vaikuttaa suoraan mm. lentoturvallisuuteen.</p> <p>Tässä työssä tutkittiin eri tavalla tuotettujen näkyvyysennusteiden laatua vuodelta 2017. Numeerisista ennustemalleista käytössä oli Harmonien tuottama näkyvyys sekä Ilmatieteen laitoksella siitä fysikaalisesti postprosessoitu tuote. Työtä varten vertailuun tuotettiin myös tilastomenetelmin kehitettyjä analogiaennusteita syys-joulukuulta.</p> <p>Eri tavoin tuotettuja näkyvyysennusteita verrattiin havaintoihin ja suoritettiin koko asemajoukolle meteorologista laadunarviointia eli verifiointia. Verifiointinnissa oli mukana yhteensä 13 lentoasemaa eri puolelta Pohjois-Eurooppaa: Suomesta, Ruotsista, Norjasta, Tanskasta, Virosta, Latviasta ja Liettuasta. Näkyvyysennusteille on olemassa Kansainvälisen siviili-ilmailujärjestön (ICAO:n) määrittelemät raja-arvot, jonka mukaan verifiointia suoritettiin. Tavoitteena oli tutkia kuinka hyvin eri tavoin tuotetut ennusteet pärjäävät havaintoihin ja toisiinsa verrattuna. Vertailussa tehtiin osuvuuksien tarkastelua kaikilla ennustepituuksilla, analysoitiin ennusteiden verifiointipisteytyksiä binääriennusteiden kautta sekä tutkittiin mallien keskihajontaa ja keskivirhettä ennustepituuksittain. Ennustepituudet muodostuivat 3, 6, 9, 12, 15, 18, 21 ja 24 tunnin mittaisista jaksoista.</p> <p>Havaittiin, että Harmonie-mallin ja siitä fysikaalisesti postprosessoidun tuotteen välillä erot korostuivat etenkin huonojen näkyvyyksien tapauksissa. Alle 150m näkyvyyksillä Harmonie sekä fysikaalisesti postprosessoitu tuote toimivat heikosti. ICAO:n näkyvyysluokkien [150, 1500m)-välillä fysikaalisesti postprosessoitu tuote osoittautui Harmonieta hieman paremmaksi. Yli 3000 metrin näkyvyysluokilla mittavia eroja mallien välillä ei ollut. Tilastomenetelmin tuotetut analogiaennusteet pärjäsivät vertailussa suhteellisen hyvin.</p> <p>Verifiointituloksista havaittiin myös, että ennustepituuden kasvattamisella 3:sta 24:n tuntiin ei ollut keskimäärin merkittävää vaikutusta Harmonien- tai fysikaalisesti postprosessoidun tuotteen toimintaan. Analogiaennusteilla yllättäen ennustepituuden vaikutus ei ollut juurikaan nähtävissä.</p> <p>Tulokset kuitenkin osoittavat, että näkyvyysennusteiden saralla kehittämistä vielä riittää sekä mallien että postprosessoitujen menetelmien osalta.</p>			
Avainsanat – Nyckelord – Keywords näkyvyys, lentosää, verifiointi			
Säilytyspaikka – Förvaringställe – Where deposited Kumpulan tiedekirjasto			
Muita tietoja – Övriga uppgifter – Additional information			

Sisältö

1	Johdanto	1
2	Havainnot	3
2.1	METAR-havainnot	3
2.2	Havaintotekniikka	3
3	Numeeriset mallit	4
3.1	Näkyvyyden määrittely ja mallien fysikaaliset toimintaperiaatteet	5
3.1.1	IFS- sekä HARMONIE-malli	6
4	Fysikaalinen ja tilastollinen postprosessointi	8
4.1	Fysikaalinen postprosessointi	8
4.2	Tilastollinen postprosessointi	9
5	Data ja sen käsittely	13
6	Verifointimenetelmät	14
7	Harmonioiden ja fysikaalisesti postprosessoidun tuotteen verifointitulokset	16
7.1	Ennusteiden osuvuus kaikilla ennustepituuksilla	16
7.2	Binääriennusteet	21
7.3	Virheen keskihajonta eri ennustepituuksilla	25
7.4	Virheen keskivirhe eri ennustepituuksilla	29
8	Analogiaennusteiden verifointitulokset	32
8.1	Ennusteiden osuvuus kaikilla ennustepituuksilla	32
8.2	Binääriennusteet	36
8.3	Virheen keskihajonta eri ennustepituuksilla	38
8.4	Virheen keskivirhe eri ennustepituuksilla	40
9	Yhteenveto	41

10 Viitteet	44
A Virheen keskihajonta eri ennustepituuksilla, Harmonie	A-1
B Virheen keskihajonta eri ennustepituuksilla, fysikaalisesti postprosessoitu tuote	B-1
C Virheen keskivirhe eri ennustepituuksilla, Harmonie	C-1
D Virheen keskivirhe eri ennustepituuksilla, fysikaalisesti postprosessoitu tuote	D-1
E Virheen keskihajonta eri ennustepituuksilla, analogiaennusteet	E-1
F Virheen keskivirhe eri ennustepituuksilla, analogiaennusteet	F-1

1 Johdanto

Lentosääennusteiden laatiminen on yksi tärkeimmistä lennon sujuvuuteen vaikuttavista tekijöistä. Ennusteiden perusteella pystytään tekemään lennonvalmistelu, johon kuuluu mm. lentoreitin valinta ja polttoaineen kulutuksen laskeminen. Lentosääennusteita eli TAF:eja (Terminal Aerodrome Forecast) laaditaan lentoasemille kolmen tunnin välein kuvaamaan vaihteluita tulevasta säästä, jotka ovat operatiivisessa mielessä merkittäviä. Suurimmille kentille, kuten Helsinki-Vantaalle, Turkuun, Tampereelle, Vaasaan, Jyväskylään, Kuopioon ja Ouluun ennusteita laaditaan aina 24h päähän, kun taas pienemmille kentille niitä tuotetaan 2-9h päähän tarpeen mukaan (Lentosääpalvelut Suomessa, 2017). Ennuste sisältää tiedon tuulennopeudesta ja -suunnasta, pilven alarajasta, näkyvyydestä, vallitsevasta säästä ja niiden merkittävistä muutoksista ennustejakson aikana. TAFissa ilmoitettavat sääparametrit raja-arvoineen ja muutosryhmineen noudattavat suoraan Kansainvälisen siviili-ilmailujärjestön eli ICAOn Annex 3:sta.

Yhtenä tärkeimpänä suureena TAF:eissa ennustetaan näkyvyyttä, joka vaikuttaa suoraan mm. lentoturvallisuuteen (Groff ja Price, 2016). Lentosäässä näkyvyysennusteiden luokkarajat määritellään sitä tarkemmaksi, mitä huonommaksi näkyvyys putoaa. Merkittävät raja-arvot määrittelee ICAO. Tämän työn motivaationa on selvittää näkyvyysennusteiden hyvyttä ICAOn määrittelemien raja-arvoin.

Tässä työssä tutkitaan eri menetelmällä tuotettujen näkyvyysennusteiden hyvyttä vuodelta 2017. Vertailuun otetaan mukaan Harmonie-säänennustusmallin tuottama näkyvyys sekä siitä fysikaalisesti postprosessoitu tuote. Mukana vertailussa on myös tilastomenetelmin lasketut analogiaennusteet neljän kuukauden ajalta. Eri tavoin tuotettuja näkyvyysennusteita verrataan lentokentiltä saatuihin havaintoihin ja suoritetaan asemajoukolle meteorologista laadunarviointia eli verifiointia. Verifiointin avulla voidaan tarkastella ennusteiden tarkkuutta, mikä tuo etenkin käyttäjälle arvokasta tietoa mallin toiminnasta.

Numeerisia ennusteita verifioidaan koko vuodelta ja tilastomenetelmin tuotettuja ennusteita pelkästään syyskuun ja joulukuun väliseltä ajalta. Ennusteet ovat piste-ennusteita lentokentiltä. Verifiointissa on mukana yhteensä 13 eri lentokenttää eri puolilta Skandinaavia ja Baltiaa. Vertailussa tehdään osuvuuksien tarkastelua kaikilla ennustepituuksilla,

tutkitaan ennusteiden verifointipisteytyksiä binääriennusteiden kautta sekä analysoidaan mallien keskihajontaa ja keskivirhettä ennustepituuksittain. Eri ennustepituuksia verrataan myös keskenään ja ne muodostuvat 3, 6, 9, 12, 15, 18, 21 ja 24 tunnin mittaisista jaksoista. Tavoitteena on tutkia kuinka hyvin eri tavoin tuotetut ennusteet pärjäävät havaintoihin ja toisiinsa verrattuna.

Havaintoina toimivat lentokenttien METAR-sääsanomat (Meteorological Aerodrome Report), joista osa on tuotettu automaattisesti ja osa manuaalisesti. Pelkästään automaattisten tai manuaalisten havaintojen käyttäminen loi dataan suuria puutteita, minkä vuoksi nämä kummatkin on yhdistetty. Tämän takia ennusteet eivät ole yhteismitallisia mittaustavoiltaan.

Yhdysvalloissa Rudack ym. (2010) ovat tutkineet jälkiprosessointimenetelmänä tuotettua paikallista ilmailumallia (Localized Aviation Model Output Statistics Program, LAMP), joka tuottaa lyhyitä 25h päähän ylettyviä ilmailuennusteita pilven alarajasta ja näkyvyydestä. Näitä ennusteita verrataan 20-km Rapid Update Cycle model (RUC20), Weather Research and Forecasting Nonhydrostatic Mesoscale Model (WRF-NMM) ja Short-Range Ensemble Forecast system (SREF) -malleihin. Verifiointissa osoittautui, että mittarilento-olosuhteiden vallitessa ja tietyillä ennustepituuksilla LAMP-malli osaa ennustaa pilven alarajan ja näkyvyyden tarkemmin kuin numeerisista malleista RUC20 ja WRF-NMM.

Aikaisempia tutkimuksia analogiaennusteiden soveltamisesta löytyy esimerkiksi Hanenin (2007) artikkelista. Siinä esitellään WIND-3 sovellus, jota on käytetty Kanadan suurimmilla lentokentillä pilven alarajan ja näkyvyyden ennustamisessa. Se hakee tietokannasta menneisyyteen kuuluvia havaintoja ja vertaa niitä sen hetkisiin. Numeerista mallia käytetään antamaan osviittaa esimerkiksi tuulessa tai sateessa tapahtuviin muutoksiin. Näiden tietojen avulla sovellus tekee deterministisen ennusteen ajassa eteenpäin. Kokemuspohjaisesti on osoittautunut, että sovellus on tuonut huomasti lisäarvoa lentosään ennustamiseen.

2 Havainnot

2.1 METAR-havainnot


METAR on sääsanoma, joka tuotetaan aina tietyssä muodossa ja tiettyyn aikaan Kansainvälisen siviili-ilmailujärjestön määräysten mukaisesti (Annex 3, 2016). Se sisältää tuulennopeuden ja -suunnan lisäksi näkyvyyden, vallitsevan sään, pilvenkorkeuden, lämpötilan ja kastepisteen sekä pintapaineen. Havaintoja tuotetaan lentokentillä aina puolen tunnin välein, 20 ja 50 yli tasatunnin. Lentosäässä raportoitavalla näkyvyydellä tarkoitetaan horisontaalista näkyvyyttä kentän pinnan tasalla eli noin 2,5 metrin korkeudella. Se ilmoitetaan nelinumeroisena lukuna metreissä.

Suomen lentokentillä havaintoja tehdään niin manuaalisesti kuin automaattisesti. Automaattisesti tuotettuja METAR-sanomia kutsutaan AUTO METAReiksi, ja niiden mittauksessa käytetään yleensä keskiarvoja tai mittausjaksoon nähden pitkäkköä havaintoaikaa. Suomessa ainoastaan Helsinki-Vantaan lentokentällä tehdään aina manuaalihavaintoja. Osalla kentistä havainnot tuotetaan aina automaattisesti, mutta on myös paikkoja missä manuaalihavaintoja tulee tornin aukioloaikojen tai havainnontekijän virka-ajan puitteissa. Havaintoja saa tehdä vain siihen koulutuksen saanut ja sertifioitu henkilö.

Manuaalisesti tehtyjä havaintoja voidaan pitää yleisesti luotettavampina, koska automaattihavainnot ovat usein joltain osin rajoittuneita. Havainnon pistemäisyyden vuoksi automaatti ei anna välttämättä edustavaa kuvaa säätilanteesta. Haasteellisia tilanteita ovat varsinkin ne, missä sää vaihtelee nopeasti tai kentällä vallitsee ilmiö, joka peittää vain osan alueesta. Myös niin kutsuttu ”näennäinen sää” aiheuttaa mittauksiin usein virhettä. Talvella varsinkin kunnossapitotöiden tai tuulen nostattama lumi pinnasta, sekä laskettelukeskuksista ajautuva tykkilumi saattavat aiheuttaa hyvinkin suuria havaintovirheitä vallitsevassa säässä ja näkyvyydessä.

2.2 Havaintotekniikka

Suomessa automaattisia näkyvyyshavaintoja tehdään pääasiassa Vaisalan kehittämällä optisella näkyvyysanturimittarilla FD12P, jonka toiminta perustuu sirontatekniikkaan. Laitteessa on infrapunavalon lähetin sekä vastaanotin (kuva 1).



Kuva 1: FD12P-mittalaitteen kaavakuva, missä: 1 = Lähetin, 2 = Vastaanotin, 3 = Mittaustilavuusalue.

Valoa siroaa herkemmin, kun lähtevän valon aallonpituus ja partikkelien kokoluokka on suurin piirtein sama. Tämä johtuu Mien sironnasta. Valonsäteen vaimentuminen on siis verrannollinen sironneen säteilyn määrään. Anturi mittaa sironneen infrapunasäteilyn intensiteettiä 33° asteen kallistuskulmalla, ja signaalikäsittelee sen meteorologiseksi näkyvyydeksi (MOR) (Weather sensor FD12P, 2002). Mitä enemmän ilmassa on esimerkiksi vesihöyryä, sitä enemmän infrapunasäteilyä siroaa vastaanottimeen. Anturi pystyy määrittämään myös jollain tarkkuudella sateen tyyppin, muttei kuitenkaan kovin luotettavasti. Suuremmat partikkelit, kuten sadepisarat tai lumihitaleet taittavat valoa eri tavoin, joten niiden tapauksessa näkyvyys määritetään toisella tavalla.

3 Numeeriset mallit

Sään ennustamiseen on kehitetty maailmassa useita erilaisia numeerisia malleja. Mallien fysikaalinen päättely on pääosin hyvin samanlainen, mutta eroja löytyy esimerkiksi käytetyistä parametrisarvoista, mallien resoluutiosta, siitä kuinka usein malliajoja tehdään ja kuinka pitkälle ajassa eteenpäin.

Harmonie (Bengtsson ym., 2017) on hienohilamalli, koska sen hilaväli on vaakasuunnassa vain 2,5km. Uusia ennusteita tuotetaan aina kolmen tunnin välein ja niiden ennustepituus on 54 tuntia. Tätä voidaan verrata esimerkiksi yleisesti käytettyyn Euroopan keskuksen tuottamaan korkean resoluution malliin (HRES), missä vaakasuuntainen hilaväli on noin 9km, uusia 10 päivän mittaisia malliajoja tehdään 12 tunnin välein.

Tässä työssä rajauduttiin käyttämään pelkästään Harmonie-mallia, koska Euroopan keskuksen mallidataa ei ollut tallennettuna tietokantaan riittävästi.

3.1 Näkyvyyden määrittely ja mallien fysikaaliset toimintaperiaatteet

Meteorologinen näkyvyys ilmakehässä (MOR, Meteorological Optical Range) määritellään Maailman ilmatieteen järjestön mukaan matkaksi, missä valovirta on pienentynyt 5%:n alkuperäisestä arvosta (WMO, 2014). Se on pisin matka miltä etäisyydeltä musta kappale voidaan nähdä ja tunnistaa, kun sitä katsotaan horisonttia vasten päivänvalossa. Yöllä pätee täysin sama sillä erolla, että yleinen valaistus nostettaisiin normaalin päivänvalon tasalle.

Näkyvyys määritellään fysikaalisesti Koschmiederin yhtälön (1) mukaisesti, missä C_x on kappaleen näennäinen kontrasti ja C_0 luontainen kontrasti. Kokonaisvaimennuskertoimista kuvaa $\beta_{tot} [\frac{1}{m}]$ ja näkyvyyttä $V [m]$. Koschmieder (1924) alkujaan oletti, että minimikontrasti, jonka havainnoija pystyy erottamaan on 2% valonlähteestä, eli $C_x = \epsilon C_0$, missä $\epsilon = 0,02$. Tästä arvosta on tehty myöhemmin tutkimuksia, joissa käytetty ϵ :n arvo vaihtelee 0,0077 ja 0,06 välillä (WMO, 2014). Harmonie-mallissa, joka pohjautuu pääpiirteissään Euroopan keskuksen kehittämään IFS-malliin (Bengtsson ym., 2017), on kuitenkin päädytty käyttämään arvoa $\epsilon = 0,02$ (S. Niemelä, 21.8.2017, henkilökohtainen tiedonanto).

$$C_x = C_0 e^{-\beta_{tot} V} \quad (1)$$

Kun näkyvyys ratkaistaan yhtälöstä (1) (WMO, 2014), saadaan sille seuraavanlainen muoto (2), mikä kertoo näkyvyyden metreissä.

$$V = \frac{-\ln \epsilon}{\beta_{tot}} \quad (2)$$

Kokonaisvaimennuskertoimen $\beta_{tot} [\frac{1}{m}]$ koostuu vaimennuskertoimien summasta, kuten aerosoleista, pilvipisaroista, pölystä sekä muista tekijöistä, jotka vaimentavat etenevän säteilyn kulkua.

3.1.1 IFS- sekä HARMONIE-malli

Euroopan keskuksen (ECMWF, European Centre for Medium-Range Weather Forecasts) kehittämä IFS-malli (Integrated Forecasting System) on kehitetty yhteistyössä Ranskan ilmatieteen laitoksen kanssa¹. ECMWF alkoi tuottaa näkyvyyssennusteita operatiiviseen käyttöön toukokuussa vuonna 2015 (IFS Documentation, 2017).

Harmonioiden näkyvyyden laskennan fysiikka perustuu pohjimmiltaan Euroopan keskuksen kehittämään IFS-malliin. Eroavaisuuksia löytyy mm. mallin käyttämisestä vakioista, kuten partikkeleiden koosta ja muodosta sekä optisten aineiden ominaisuuksista. Vuoden 2017 syyskuussa Ilmatieteen laitoksella Harmonie-mallista siirryttiin niin kutsuttuun MetCoOp EPS-malliin² (MetCoOp - Meteorological Co-operation on Operational Numerical Weather Prediction, EPS - Ensemble Prediction System), eli lyhennettynä MEPS:iin. MEPS:in takana on edelleen Harmonie-malli, josta tehtiin samalla päivitys vanhasta 38h1.2. syklistä uuteen 40h1.1. sykliin. Malliajoja tehdään nykyään yhdessä Norjan ja Ruotsin kanssa, ja parven jäseniä on 9+1 kappaletta, mistä erillinen 1 tarkoittaa ns. kontrolliennustetta, jota ei ole häiritty. Tavoitteena on siis tuottaa todennäköisyssennusteita pohjoismaisena yhteistyönä, mistä MEPS:in nimityskin johtaa. Tämä siirros ei tuottanut muutoksia näkyvyyden laskennan koodissa. Näkyvyysarvoissa voi silti mahdollisesti odottaa olevan pieniä muutoksia, koska mallit ovat ominaisuuksiltaan hieman erilaiset, ja varsinkin näkyvyyden laskentaan tarvittava pilvisyys ja siihen liittyvät ominaisuudet muuttuivat (C. Fortelius, 29.6.2018, henkilökohtainen tiedonanto).

Meteorologisesti tarkastellen löytyy lukuisia tekijöitä, joiden vuoksi näkyvyys voi eri tilanteissa heikentyä. Tämän vuoksi erilaisia tilanteita pyritään mallintamaan niin tarkasti kuin mallissa on mahdollista. Numeerinen malli pystyy yksinkertaistettuna ennustamaan ilmakehässä mm. vesihöyryn määrää, pilven vesihöyry- ja jääsisäلتöä, sekä sateen ja lumisateen intensiteettiä. Erilaisia aerosoleja, kuten sulfaatteja, merisuolaa, pölyä ja nokea pyritään huomioimaan kuukausittaisen klimatologisen jakauman perusteella pohjautuen Tegenin ym. (1997) artikkeliin. Sekä Harmonie ja ECMWF käyttävät samaa klimatologista jakaumaa. Vertikaalisuuntaista ulottuvuutta mallinnetaan molemmissa mal-

¹<https://www.ecmwf.int/en/research/modelling-and-prediction>, viitattu 7.9.2018

²https://metcoop.smhi.se/dokuwiki/_media/nwp/metcoop/changelog/2017-06-meps_change_notification.pdf, viitattu 7.9.2018

leissa Tanrén ym. (1984) klimatologian perusteella, kuten IFS:n dokumentaatiossa sekä Bengtssonin ym. (2017) artikkelissa kerrotaan. Säämallit pystyvät siis ennustamaan suhteellisen hyvin esimerkiksi sateesta, lumisateesta tai sumusta johtuvan näkyvyyden huononemisen, mutta satunnaisia ja runsaita hiukkaspäästöjä se ei kuitenkaan pysty ottamaan huomioon.

Esimerkiksi sumutilanteissa, jolloin vesihöyry on tiivistynyt maanpinnan lähetyvillä, näkyvyys putoaa alle yhteen kilometriin. Sumujen ennustamisessa orografiasta johtuvat alueelliset erot mallin ja todellisuuden välillä voivat olla hyvinkin suuria, vaikka mallin lähtötiedot ovatkin tarkkoja. Tästä johtuen mallien ennustamat arvot voivat poiketa hyvinkin paljon todellisuudesta. Sumun muodostuminen vaihtelee hyvin paljon aika- ja paikkakohtaisesti: sen muodostuminen tai hälveneminen riippuu hyvin tarkasti pinnan tyypistä, maaperän kosteudesta ja lämpötilasta, säteilypakotteesta sekä dynaamisista ja termodynaamisista olosuhteista rajakerroksessa. Näitä ei kuitenkaan pystytä mallintamaan tarpeeksi tarkasti säämalleissa.

Näkyvyys määritetään mallin alimmalla pinnalla, noin kymmenen metrin korkeudella, laskemalla vaimennuskertoimien (engl. extinction coefficient) summa, β_{tot} , optisille aallonpituuksille ilmakehässä. Näkyvyys määritellään kaavan (2) mukaan, missä ϵ :lle käytetään vakiintunutta arvoa 0,02 sekä Harmoniessa että Euroopan keskuksen mallissa (IFS Documentation, 2017).

Kokonaisvaimennuskerroin, β_{tot} , koostuu puhtaasta ilmasta, aerosoleista, pilvistä ja sateesta, eli vaimennuskertoimien summasta (3). Puhtaalle ilmalle vaimennuskerroin on pieni, koska maksiminäkyvyydeksi määritellään 100km.

$$\beta_{tot} = \beta_{air} + \beta_{aerosol} + \beta_{cloud} + \beta_{precip} \quad (3)$$

Aerosoleihin sisältyy monia eri lajeja, kuten merisuoloja, pölyä, nokea, orgaanisia aineita ja sulfaatteja. On myös yksilöimättömiä aerosoleja, joita kutsutaan ”taustaksi”. Molemmat mallit käyttävät näille samaa optista paksuutta: 0,03. Aerosolien vaimennuskerroin saadaan laskettua niiden eri lajien summasta (4). Harmonie käyttää näille kuukausittaisia keskiarvoja suoraan Tegenin ym. (1997) tutkimusartikkeliin pohjautuen. Tässä klimatologiassa aerosolien optisia paksuuksia on kuitenkin aliarvioitu Euroopan alueella, etenkin Atlantin valtameren rannikoilla, verrattuna uudempiin tutkimuksiin (Bengtsson, L. ym.,

2017).

$$\beta_{aerosol} = \beta_{seasalt} + \beta_{dust} + \beta_{blackcarbon} + \beta_{organic} + \beta_{sulphates} + \beta_{background} \quad (4)$$

Vaimennuskertoimet pilville ja sateelle ovat ilmaistu pilviveden sekä pilven jää-, vesi- ja lumisisällön avulla (5).

$$\beta_{cloud} + \beta_{precip} = \beta_{liq} + \beta_{ice} + \beta_{rain} + \beta_{snow} \quad (5)$$

Vaimennuskertoimet pilvivedelle ja -jälle lasketaan Harmoniessa hieman eri parametreja käyttäen kuin Euroopan keskuksen IFS-mallissa. Parametrisoinnit pohjautuvat eri tutkimusartikkeleihin. Parametrisointi Harmonien pilviveden optisille ominaisuuksille on esitetty Nielsenin ym. (2014) artikkelissa ja jälle Fu'n (1996) tutkimusartikkelissa. Pilvipisaroiden efektiivinen säde pohjautuu tutkimusartikkeliin "Martin ym., 1994" ja efektiivinen säde jälle saadaan tutkimusartikkeleista "Sun ja Rikus, 1999" sekä "Sun, 2001".

4 Fysikaalinen ja tilastollinen postprosessointi

4.1 Fysikaalinen postprosessointi

Operatiivisessa ennustetyössä on havaittu, että suoraan mallin tuottamissa ennustesuureissa on puutteita varsinkin Suomen olosuhteissa. Tämän takia Ilmatieteen laitoksella on koettu tarpeelliseksi jatkokehittää mallin tuottamia näkyvyysennusteita kvantitatiivisesti. Näkyvyysennusteiden jatkokäsittelyyn on kehitetty fysikaalispohjainen algoritmi, joka toimii ennustemalleista riippumatta. Se tasoittaa esimerkiksi malleissa esiintyviä suuria gradientteja hyvien ja huonojen näkyvyyksien välillä, mm. rintamasateiden reunalla. Näkyvyys tässä algoritmissa lasketaan kahdessa eri osiossa: Ensin lasketaan näkyvyys sateessa, mihin vaikuttaa sateen olomuoto, intensiteetti sekä kosteus ja sumupilvisyys. Sumupilven maksimikorkeudeksi määritetään 305m. Toisena lasketaan sumupilven avulla päätelty näkyvyys, mihin vaikuttaa matalan pilven määrä ja korkeus ³.

³<https://github.com/fmidev/himan/blob/master/himan-plugins/source/visibility.cpp>, viitattu 7.9.2018

Numeerisen ennustemallin antama näkyvyys sateessa lasketaan pääasiassa olomuodon, intensiteetin ja kosteuden perusteella. On huomattu, että malli ei saa aina heikoimpia lumi- tai räntäsateesta johtuvia näkyvyyden huononemisia kiinni, minkä vuoksi näiden intensiteettiä on hieman tehostettu.

Algoritmin näkyvyyden laskenta sateen eri olomuodoissa lasketaan intensiteetin perusteella, jota voidaan huonontaa niin kutsutuilla utuisuuskertoimilla. Utuisuuskertoimet sateessa määritetään suhtellisen kosteuden, sumupilven määrän ja -korkeuden perusteella. Sumupilven määrän ja -korkeuden avulla voidaan myös erikseen laskea utuisuuskertoimia. Havaintoihin nojaten, näille parametreille on löydetty tietyt raja-arvot, jotta tilanne on saatu vastaamaan paremmin todellisuutta.

Lopuksi valitaan sadetilanteen avulla päätellyn näkyvyyden tai sumupilven avulla päätellyn näkyvyyden väliltä huonompi arvo, mikä valitaan postprosessoidun tuotteen lopulliseksi tulokseksi. Näkyvyysalgoritmin kehittäminen perustuu hyvin paljolti empirisiin havaintoihin, jonka myötä tuotetta on kehitetty eteenpäin.


4.2 Tilastollinen postprosessointi

Numeeristen mallien laskemissa näkyvyysarvoissa on usein virhettä varsinkin silloin, kun näkyvydet putoavat huonoiksi esimerkiksi rankkasateen, udun tai sumun takia. Virheet johtuvat mm. siitä, ettei monimutkaisia fysikaalisia prosesseja pystytä mallintamaan tarpeeksi tarkasti. Myös laskentakapasiteetin rajallisuus luo haasteita.

Analogiamenetelmällä tuotetut ennusteet tehdään pohjautuen tilastoihin eli menneisyyden havaintoihin. Tässä työssä tuotettiin tilastoihin pohjautuvia ennusteita samalla tavalla kuten Tuba ja Bottyan (2017) ovat esittäneet. Menetelmän tarkoituksena on löytää havaintohistoriasta eniten samankaltainen tilanne kuin vertailussa oleva, ja tehdä tätä jäljitellen ennuste ajassa eteenpäin. Tässä työssä havaintohistoriaa vastaa vuosien 2010-2017 METAR-havainnot ja vertailukautta vuoden 2017 syyskuusta joulukuuhun olevat havainnot. Tietyn pituista havaintojaksoa verrataan historiaan ja yritetään löytää mahdollisimman samankaltainen tilanne menneisyydestä samankaltaisuuden (engl. degree of similarity) perusteella.

Kahden parametrin välistä samankaltaisuutta voidaan kuvata sumean logiikan tavoin,

missä yksittäinen arvo voi vaihdella 0 ja 1 välillä. Mitä pienempi ero on kahden paramet-
rin suhteen, sitä samankaltaisempi tilanne on. Esimeriksi kuvassa 2 verrataan lämpöti-
laparametrejä. Tilanne on täysin samankaltainen ($=1$), kun lämpötilaero on tasan nolla.
Mikäli ero on yli 5°C tai alle -5°C astetta, niin tilanne ei ole yhtään samankaltainen ($=0$).



Kuva 2: Esimerkkikuva sumeasta logiikasta, missä x-akselilla on lämpötilaero ja y-akselilla samankaltaisuusasteikko. Kuva: Tuba ja Bottyan (2017).

Ennusteiden muodostamista varten ensin havaintojen jokaista parametriä verrataan historiahavaintojen kanssa. Tässä tapauksessa vertailussa ovat pintapaine, lämpötila, kas-
tepiste, tuulennopeus ja -suunta, näkyvyys, päivä ja vuorokaudenaika. Jokaiselle paramet-
rille määritetään erikseen omat raja-arvot, joiden perusteella samankaltaista säätilannet-
tä arvioidaan. Sumean logiikan keinoin saadaan arvot samankaltaisuuksille.

Eri suureille käytettiin erilaisia samankaltaisuuden arvoja, joiden välillä interpoloitiin
lineaarisesti. Arvot on esitetty taulukossa 1. Näkyvyys on määritelty suhteellisina osuuk-
sina ja muut parametrit erotuksina. Jos esimerkiksi näkyvyys saa arvon 2400m ja men-
neessä havainnossa se on 2000m, on näiden välinen suhdeluku 1,2. Samankaltaisuusindeksi
saa tällöin arvon 0,9.

Samankaltaisuus	0	0,2	0,5	0,7	0,9	1	0,9	0,7	0,5	0,2	0
Pintapaine (hPa)	-100	-80	-60	-40	-20	0	20	40	60	80	100
Lämpötila/kastepiste (°C)	-5	-4	-3	-2	-1	0	1	2	3	4	5
Tuulennopeus ($\frac{m}{s}$)	-5	-4	-3	-2	-1	0	1	2	3	4	5
Tuulensuunta (°)	-100	-80	-60	-40	-20	0	20	40	60	80	100
Näkyvyys (m)	1/2	1/1,8	1/1,6	1/1,4	1/1,2	1	1,2	1,4	1,6	1,8	2
Vuorokaudenaika (h)	-5	-4	-3	-2	-1	0	1	2	3	4	5
Päivä (vrk)	-100	-80	-60	-40	-20	0	20	40	60	80	100

Taulukko 1: Samankaltaisuudet eri suureille.


Kun parametreille on löydetty tiedot samankaltaisuuksista, voidaan tämän jälkeen jokaista yksittäistä parametriä vielä painottaa. Painotetut kertoimet ovat listattuna taulukossa 2. Nämä arvot ovat itse subjektiivisesti arvioituja, ja niiden herkkyytstarkastelu ei ollut tässä työssä mahdollista. Arvoja käyttäen voidaan laskea samankaltaisuusindeksit historiahavaintojen välillä yhteenlaskemalla kaikkien parametrien yksittäiset samankaltaisuudet keskenään, kun jokaista arvoa on painotettu. Kaikkia saatavia parametrejä, kuten pilven alarajaa ei voitu ottaa mukaan havaintojen ollessa puuttellisia tai vaikeasti määritettäviä.

Näkyvyys	0.321
Vuorokaudenaika tunteina	0.107
Päivä	0.071
Pintapaine	0.071
Lämpötila	0.107
Kastepiste	0.107
Tuulen suunta	0.143
Tuulen nopeus	0.071
	=1.00

Taulukko 2: Painotetut arvot eri parametreille.

Samankaltaisuuksien löytämisen ja painotuksien jälkeen suoritetaan vielä ajallinen

painotus niin, että nykyinen havainto saa suurimman painon, ja painotus vähenee eksponentiaalisesti kuvan 3 mukaisesti. Tässä työssä ennusteiden muodostamista varten yhtä säätilannetta kuvaamaan käytettiin 12:ta METAR-havaintosarjaa, mikä tarkoittaa ajallisesti kuuden tunnin pituista jaksoa. Lopulta 24 tunnin ennusteen alkuhetkeksi valitaan kaikkein samankaltaisin säätilanne historiasta. Ennustettavan ajanhetken ympäriltä poistettiin 15 päivää molemmin puolin, jottei autokorrelaatio sotke ennusteita.



Kuva 3: Painotuksien laskeminen kahdelletoista METAR-havaintosarjalle. X-akselilla sijaitsee aika-askeleet, missä 1 tarkoittaa viimeisintä ja 12 vanhinta havaintoa. Y-akselille on merkitty aika-askeleen ajallinen painoarvo. Viimeisin havainto saa eniten painoa, jonka jälkeen painotus tippuu eksponentiaalisesti.

5 Data ja sen käsittely

Työssä käytettiin hyväksi Ilmatieteen laitoksen TAF-verifointitietokantaan talletettua dataa, jota oli saatavissa kohtuullisesti vuodelle 2017. Malleista käytettiin Harmonie-mallin omaa näkyvyyttä sekä meteorologien kehittämää postprosessoitua näkyvyyttä. Harmonielle ajoja tehdään aina kolmen tunnin välein, joten työhön pystyttiin ottamaan mukaan 3, 6, 9, 12, 15, 18, 21 ja 24 tunnin ennustepituudet. Pidempiä ennustepituuksia ei ollut tarpeen käsitellä, koska työn mielenkiinto rajautuu lentosääennusteiden pariin.

METAReista karsittiin kaikki 50 yli tasatunnin tehdyt havainnot pois, koska 20 yli tehdyt havainnot olivat edustavampia tässä tilanteessa. Tehty säähavainto kuvastaa aina viimeisintä puolen tunnin säätä, ja mallit laskevat näkyvyysarvot aina tasatunneille. Esimerkiksi mallin tuottama lukema tunnille 12:00, on havainnoissa vastaavasti 12:20, joka kuvastaa 11:50-12:20 välisen ajankohdan vallitsevaa säätä.

Verifioinnissa olisi tärkeää, että kaikki havainnot olisivat yhteismitallisia. Valitettavasti tässä työssä päädyttiin käyttämään kuitenkin sekä havainnontekijöiden että automaattien tuottamia METAR-näkyvyyshavaintoja, koska muutoin verifointia ei olisi voinut suorittaa. Havaittiin, että pelkästään automaattien tuottamat havainnot loivat dataan valtavia puutteita varsinkin suurimmilta lentokentiltä. Isompi datamäärä oli täysi välttämättömyys myös analogiaennusteiden laskennan kannalta.

Analogiaennusteet laskettiin vain syyskuusta joulukuuhun johtuen tietokoneiden rajallisesta laskentakapasiteetista. Niiden tuottamiseen tarvittiin myös vuosien 2010-2017 METAR-havainnot, jotka toimivat havintohistoriana. Mikäli havainnoista puuttui 3h tai vähemmän arvoja, ne interpoloitiin lineaarisesti havaintojen välille. Yhdelle asemalle neljän kuukauden mittainen ennusteiden tuottaminen kesti noin kaksi viikkoa yhdellä ytimellä. Tämä toistettiin jokaiselle 13 eri asemalle.

Datan käsittely ja verifointi suoritettiin R-kielellä. Tilastollisia eroavaisuuksia ei tutkittu, joten erot aineistojen välillä voivat johtua myös sattumasta. Yksityiskohtainen asematarkastelu jätettiin tämän työn ulkopuolelle.

6 Verifiointimenetelmät

Ennusteen meteorologista laadunarviointia kutsutaan verifiointiksi. Ennustamiseen liittyy yleensä virhettä, ja ennustuspituuden kasvaessa myös virhe kasvaa.

Lentosäässä näkyvyyden ennustamisen kannalta on olennaista, että ennusteet osuvat havaintojen kanssa samoille luokkaväleille, jotka Kansainvälinen siviili-ilmailujärjestö on määritellyt. ICAOn raja-arvot näkyvyydelle ovat esitetty taulukossa 3 ja ne tulevat suoraan Annex 3:sta (2016). Suomessa on anottu erikseen 8000m raja-arvo, mikä on poikkeusluvalla myönnetty. Kyseinen raja-arvo ei ole yleisesti käytössä muissa maissa.

0m-	150m-	350m-	600m-	800m-	1500m-	3000m-	5000m-	8000m-
-----	-------	-------	-------	-------	--------	--------	--------	--------

Taulukko 3: ICAO-luokat näkyvyydelle

Ilmatieteen laitos verifioi jokaisen lentosääennusteen eli TAF:in, ja pisteytys tapahtuu sen mukaan kuinka hyvin ennuste osuu havaintojen mukaiselle luokkavälille (Blanco Sequeiros, A. ym.). Taulukossa 4 on esitetty verifiointiin liittyvä pisteytys, joka lasketaan osuman mukaan. Järjestelmä on hyvin ehdoton, koska yli kaksi luokkaa pielessä oleva ennuste on käytännössä täysin väärin.

Luokkaero	Pisteet
0	10
1	7
2	1
3	0

Taulukko 4: Ennusteiden pisteytys. Yli kaksi luokkaa pielessä olevat ennusteet ovat täysin väärin.

Tässä työssä käytetään hyväksi edellä mainittua ICAO:n luokkajakoa, jonka mukaan verifiointia suoritetaan. Asemien ICAO-lyhenteet ovat suomennettuna taulukossa 5 ja kartalla kuvassa 4.

Asema	Nimi	Asema	Nimi
EFRO	Rovaniemi lentoasema	EFOU	Oulu
EFKU	Kuopio	EFJY	Jyväskylä
EFTP	Pirkkala	EFHK	Helsinki-Vantaa
ESPA	Lulea-Kallax	ESSA	Tukholma, Arlanda
ENGM	Oslo, Gardermoen	EKCH	Kööpenhamina, Kastrup
EETN	Tallinna	EVRA	Riika
EYVI	Vilna		

Taulukko 5: Asemien ICAO-tunnukset suomeksi.



Kuva 4: Asemat havainnollistettuna kartalla.

7 Harmonien ja fysikaalisesti postprosessoidun tuotteen verifiointitulokset

7.1 Ennusteiden osuvuus kaikilla ennustepituuksilla

Koko asemajoukko jaettiin mallien ja havaintojen osalta ICAO:n määrittelemiin luokkiin. Tämän jälkeen verrattiin kaikkia 3-24h ennustepituuksia sekä kaikkien asemien havaintoja keskenään kronologisessa järjestyksessä koko vuodelta. Muodostettiin taulukko malli-havaintoparien vastaavuuksista. Taulukossa 6 ja 7 on esitetty, mihin luokkiin ennusteet ovat osuneet havaintojen suhteen. Taulukko 6 kuvaa Harmonie-mallin omaa näkyvyyttä ja taulukko 7 fysikaalisesti postprosessoitua tuotetta. Diagonaalilla näkyy lukuarvot, jolloin ennuste on mennyt täsmälleen oikein eli osunut samaan luokkaan havainnon kanssa. Jokaisesta luokasta on laskettu myös rivi- ja sarakesummat. Kokonaislukumäärä taulukkojen välillä poikkeaa toisistaan, koska postprosessoidulla mallituotteella oli hieman enemmän puuttuvia arvoja datassa.

	Harmonie									
Havainnot	[0-150)	[150-350)	[350-600)	[600-800)	[800-1500)	[1500-3000)	[3000-5000)	[5000-8000)	[8000-9999]	summa
[0-150)	288	108	36	25	53	119	120	55	152	956
[150-350)	1499	552	259	120	313	851	461	341	666	5062
[350-600)	1495	690	269	153	422	919	479	260	720	5407
[600-800)	771	289	140	101	333	642	252	192	411	3131
[800-1500)	1283	993	445	221	1254	2660	788	586	1080	9310
[1500-3000)	1377	1217	746	523	2615	7298	2893	1619	2287	20575
[3000-5000)	1204	1309	793	471	2907	8732	4661	3238	4680	27995
[5000-8000)	1380	1481	880	569	2699	9967	6979	5768	10059	39782
[8000-9999)	8312	7761	4458	2585	8947	51816	59449	73593	484136	701057
summa	17609	14400	8026	4768	19543	83004	76082	85652	504191	813275

Taulukko 6: Ennusteiden osuvuus luokittain Harmonie-mallin näkyvyydelle niin, että y-akselilla on havaittu näkyvyys ja x-akselilla mallin näkyvyys. Mukana ovat kaikki ennustepituudet sekä kaikkien asemien havainnot. Diagonaalilla värjätyt luvut ovat täysin oikein menneitä ennusteita.

	Postprosessoitu									
Havainnot	[0-150)	[150-350)	[350-600)	[600-800)	[800-1500)	[1500-3000)	[3000-5000)	[5000-8000)	[8000-9999]	summa
[0-150)	0	275	86	36	62	48	53	45	349	954
[150-350)	0	1168	939	266	297	420	288	280	1391	5049
[350-600)	0	1294	953	304	531	444	317	268	1272	5383
[600-800)	0	554	504	250	393	386	215	150	670	3122
[800-1500)	2	1339	1225	677	1612	1496	723	472	1735	9281
[1500-3000)	0	1669	1538	807	3034	5161	3073	1783	3425	20490
[3000-5000)	0	1635	1498	869	2888	6044	4639	3592	6678	27843
[5000-8000)	0	1801	1743	976	2953	6373	6206	6033	13369	39454
[8000-9999)	33	11978	10377	5095	14050	28488	33435	43532	541397	688385
summa	35	21713	18863	9280	25820	48860	48949	56155	570286	799961

Taulukko 7: Ennusteiden osuvuus luokittain postprosessoidulle tuotteelle niin, että y-akselilla on havaittu näkyvyys ja x-akselilla mallin näkyvyys. Mukana ovat kaikki ennustepituudet sekä kaikkien asemien havainnot. Diagonaalilla värjätyt luvut ovat täysin oikein menneitä ennusteita.

Taulukoiden 6 ja 7 ja sarake- ja rivisummia verrattiin luokittain laskemalla suhteelliset osuudet mallien (sarakeet) ja havaintojen (rivit) välillä. Näistä saatiin taulukon 8 mukainen jakauma. Taulukon arvot kertovat kuinka moninkertaisesti malli pyrkii yliennustamaan havaintoihin verrattuna ko. näkyvyysluokan määriä. Mikäli arvo poikkeaa luvusta yksi (=1) ylöspäin, niin malli pyrkii yliennustamaan. Mikäli poikkeama on alaspäin, niin malli pyrkii aliennustamaan.

Esimerkiksi havaintoluokan [0,150m)-välillä Harmonien natiivi pyrkii ennustamaan 18,42 kertaisesti liikaa, kun taas postprosessoitu versio pyrkii ennustamaan 0,037 kertaa liian paljon eli noin 27 kertaisesti liian vähän. Luokkien [150,1500m)-välillä Harmonie yliennustaa, mutta vähemmän kuin postprosessoitu malli. Toisaalta luokkien [1500,8000m)-välillä postprosessoitu tuote yliennustaa vähemmän kuin Harmonie itse. Yli 8km näkyvyyksillä Harmonie ennustaa noin 1,4 kertaa liian vähän kyseistä luokkaa, kun taas postprosessoitu aliennustaa noin 1,2 kertaisesti. Näistä kuitenkin postprosessoitu tuote aliennustaa vähemmän.


Harmonien oman näkyvyyden ja postprosessoidun tuotteen välillä nähdään siis selvä ero 1500m näkyvyyksien vaihteessa. Harmonie yliennustaa vähemmän alle 1500 metrin näkyvyyksillä, kun taas yli 1500 metrin mutta alle 8000 metrin näkyvyyksillä postprosessoitu malli yliennustaa vähemmän.

Havaintoluokat (m)	[0-150)	[150-350)	[350-600)	[600-800)	[800-1500)	[1500-3000)	[3000-5000)	[5000-8000)	[8000-9999]
Harmonie	18,419	2,845	1,484	1,523	2,099	4,034	2,718	2,153	0,719
Postprosessoitu	0,037	4,300	3,504	2,972	2,782	2,385	1,758	1,423	0,828


Taulukko 8: Suhteelliset osuudet laskettuna sarakesummista luokittain. Arvot kertovat kuinka moninkertaisesti malli pyrkii yliennustamaan kyseisen luokan toteutumislukumäärää havaintoihin verrattuna. Harmaalla sävyllä on korostettu paremmin pärjännyt malli.

Kuvassa 5 näkyy prosentuaaliset osuudet sekä Harmonie-mallin omasta, että meteorologien kehittämän postprosessoidun tuotteen toiminnasta. Lukuarvot kertovat kuinka hyvin on pystytty ennustamaan täysin oikeaa luokkaväliä. Mukana ovat kaikki asemat ja kaikki ennustepituudet, joihin havaintoja verrattiin. Postprosessoitu tuote ei ennusta oikein alle 150m näkyvyyksiä, jonka vuoksi postprosessoidun tuotteen ensimmäinen arvo on nolla. Nähdään, että kaiken kaikkiaan postprosessoitu tuote toimii hieman paremmin luokkien [150,1500m) välillä. Muutoin kovin suuria eroja ei ole. Vaakaviivoilla on laskettu sekä natiivin että postprosessoidun tuotteen keskiarvo luokkakohtaisista arvoista. Keskimäärin suuria eroja tuotteiden välillä ei ole.

Kuvassa 6 on esitetty samankaltaiset prosenttiosuudet, mutta sillä erolla, että ennuste poikkeaa havainnosta enintään yhden luokan. Tässä tilanteessa postprosessoidun ja Harmonie-mallin toiminnan erot keskimäärin korostuvat. Postprosessoitu tuote on tässä tilanteessa jo selvästi prosentuaalisesti parempi luokkien [350,800m) välillä. Muutoin merkittäviä luokkien välisiä eroja ei ole.



Kuva 5: Osumatarkkuudet eli kaikkien havaintoasemien lasketut suhteet siitä, kuinka monta prosenttia ennusteista osuu täysin oikeaan luokkaan havaintojen suhteen. Sininen käyrä kuvaa mallin omaa näkyvyyttä ja punainen postprosessoitua tuotetta. Vaakaviivoilla on keskiarvo luokkakohtaisista arvoista.



Kuva 6: Osumatarkkuudet eli kaikkien havaintoasemien lasketut suhteet siitä kuinka monta prosenttia ennusteista osuu samaan luokkaan tai yhden luokan pieleen havaintojen suhteen. Musta käyrä kuvaa mallin omaa näkyvyyttä ja vihreä postprosessoitua tuotetta. Vaakaviivoilla on keskiarvo luokkakohtaisista arvoista.

7.2 Binääriennusteet

Osumuuksien lisäksi on hyvä vielä tarkastella ennusteiden onnistuneisuutta kontingenssitaulukon avulla (taulukko 9). Lähteenä käytettiin kirjaa “Forecast Verification” (Jolliffe ja Stephenson, 2003). Ennusteiden ja havaintojen välisistä pareista muodostuu neljä erilaista yhdistelmää: osuma (hit), väärä hälytys (false alarm), huti (miss) ja oikea negatiivinen (correct negative). Taulukon avulla pystytään laskemaan millaisia virheitä ennusteet ovat tuottaneet. Näitä binäärisiä ennusteita pisteytetään sen mukaan, mihin lokeroon ne osuvat. Optimitilanteessa luokitus tuottaisi pelkästään osumia (a) ja oikeita negatiivisia (d).

Taulukon avulla voidaan laskea erilaisia verifiointisuureita kuten POD (Probability Of Detecton), FAR (False Alarm Ratio), POFD (Probability Of False Detection) ja PSS (Peirce’s Skill Score). Tässä tutkimuksessa kyllä-tilanteella tarkoitetaan, että näkyvyys on osunut tietylle luokkavälille. Näkyvyysluokkina käytettiin ICAOn luokkajakoa.

	Havaittu kyllä	Havaittu ei
Ennustettu kyllä	osuma (a)	väärä hälytys (b)
Ennustettu ei	huti (c)	oikea negatiivinen (d)

Taulukko 9: Kontingenssitaulukko.

Osumatarkkuus eli POD kertoo kuinka usein havaitut ilmiöt ennustettiin oikein. Osumatarkkuus voidaan laskea kaavan 6 mukaisesti, ja se voi saada arvoja 0 ja 1 väliltä, niin että 1 viittaa täydelliseen ennusteeseen.

$$\text{POD} = \frac{\text{osumat}}{\text{osumat} + \text{hudit}} = \frac{a}{a + c} \quad (6)$$

Väärä hälytyssuhde eli FAR kertoo puolestaan sen, kuinka usein ennustettuja ilmiöitä ei havaittu. Tämän avulla saadaan tietää osuus kuinka paljon malli yliennustaa. Väärä hälytyssuhde lasketaan kaavan 7 mukaisesti, ja se saa arvoja 0 ja 1 väliltä. Tässä tapauksessa 0 viittaa täydelliseen ennusteeseen, koska optimitilanteessa vääriä hälytyksiä ei ole ollenkaan.

$$\text{FAR} = \frac{\text{väärät hälytykset}}{\text{osumat} + \text{väärät hälytykset}} = \frac{b}{a + b} \quad (7)$$

POFD kuvaa yliennustettavuuden määrää eli kuinka usein ei-havaituista ilmiöistä oli ennustettu virheellisesti kyllä-tapauksina. Se saa myöskin arvoja 0 ja 1 väliltä niin, että täydellinen tulos on 0.

$$\text{POFD} = \frac{\text{väärät hälytykset}}{\text{väärät hälytykset} + \text{oikeat negatiiviset}} = \frac{b}{b + d} \quad (8)$$

Peirce Skill Score eli PSS kuvaa, kuinka hyvin ennuste pystyy erottelemaan “kyllä”-tapaukset (POD) “ei”-tapauksista (POFD). Täydellisessä tilanteessa PSS saa arvon 1, ja sen arvo voi vaihdella kaikkiaan -1 ja 1 välillä. Harvinaisemmille tapauksille, missä oikeiden negatiivisten (d) määrä on suhteellisen suuri ja täten myös POFD pieni, PSS pyrkii painottamaan liikaa ensimmäistä termiä, joten POD voi joissain tapauksissa olla hyödyllisempi useasti toistuvilla ilmiöillä.

$$\text{PSS} = \underbrace{\frac{\text{osumat}}{\text{osumat} + \text{hudit}}}_{\text{POD}} - \underbrace{\frac{\text{väärät hälytykset}}{\text{väärät hälytykset} + \text{oikeat negatiiviset}}}_{\text{POFD}} = \frac{a}{a + c} - \frac{b}{b + d} \quad (9)$$

Jokaiselle ICAO-luokalle laskettiin erikseen yllä olevat tunnusluvut. Taulukoiden 6 ja 7 sarakesummat näkyvyysluokkien [150,1500m) -välillä poikkeavat toisistaan huomasti: postprosessoidulle tuotteelle otoskoot ovat selvästi suuremmat, jonka vuoksi osuma-

tarkkuudetkin (POD) ovat paremmat. Tämän vuoksi on tarve selvittää myös muiden tunnuslukujen arvoja.

Taulukosta 10 huomataan että luokkarajalla [0,150m) postprosessoitu tuote ei ennusta ollenkaan osumia (a). Väärien hälytysten suhde (FAR) on niin suuri, että malli pyrkii yliennustamaan aina.

Tunnusluvut osoittavat, että osumatarkkuudet ovat [150,1500m) näkyvyyksillä postprosessoidulle tuotteelle paremmat kuin Harmonielle. Tätä kuvastaa myös kuva 5. Myös väärien hälytysten suhde (FAR) on hieman pienempi postprosessoidulle tuotteelle, eli Harmoniella “kyllä”-ennuste jäi useammin toteutumatta.

Luokkavälillä [1500,3000m) Harmonien osumatarkkuudet ovat parempia, mutta väärä hälytyssuhde on suurempi kuin postprosessoidulla tuotteella.

Yli 3000m näkyvyyksillä Harmonien ja postprosessoidun tuotteen osumatarkkuuksien välillä suuria eroja ei ole. Suurin ero havaitaan siinä, että Harmoniella väärien hälytysten suhde on selvästi suurempi [3000,8000m) luokkavälillä.

Yhteenvedetty tulos, kuten Peirce’s Skill Score kuvaa Harmonien ja postprosessoidun tuotteen ennusteita erottaa “kyllä”-tapaukset “ei”-tapauksista. Postprosessoitu tuote saa parempia PSS:n arvoja luokkavälillä [150,1500m) ja [3000,9999m). Taulukon 10 perustella voidaan sanoa, että Harmonie ennustaa useasti hutia (c), jolloin myös Peirce Skill Scoren ensimmäinen termi (POD) painottuu verrattaen paljon välillä [150,1500m).

LUOKKA		HARMONIE	POSTPROSESSOITU
0-150	POD	0.3012552301	0
	FAR	0.9836447271	1
	F	0.0213229039	4.38E-05
	PSS	0.2799323262	-4.38E-05
150-350	POD	0.1090478072	0.2313329372
	FAR	0.9616666667	0.9462073412
	F	0.0174949434	0.0258688639
	PSS	0.0915528638	0.2054640733
350-600	POD	0.0497503237	0.1770388259
	FAR	0.9664839272	0.9494778137
	F	0.0099805073	0.0231985203
	PSS	0.0397698163	0.1538403057
600-800	POD	0.0322580645	0.0800768738
	FAR	0.9788171141	0.9730603448
	F	0.0060565241	0.0119454557
	PSS	0.0262015404	0.0681314181
800-1500	POD	0.1346938776	0.1736881802
	FAR	0.9358338024	0.9375677769
	F	0.0239931572	0.032534792
	PSS	0.1107007204	0.1411533882
1500-3000	POD	0.3547023086	0.2518789653
	FAR	0.9120765264	0.8943716742
	F	0.1022527591	0.0610878357
	PSS	0.2524495496	0.1907911297
3000-5000	POD	0.1664940168	0.1666127932
	FAR	0.938737152	0.9052278903
	F	0.1056436153	0.0655075095
	PSS	0.0608504015	0.1011052837
5000-8000	POD	0.1449901966	0.1529122522
	FAR	0.9326577313	0.8925652213
	F	0.1288100502	0.0781287264
	PSS	0.0161801464	0.0747835258
8000-9999	POD	0.6905800812	0.7864741387
	FAR	0.0397765926	0.0506603681
	F	0.1787146447	0.2589309721
	PSS	0.5118654365	0.5275431667

Taulukko 10: Verifointisuureet Harmonielle ja fysikaalisesti postprosessoidulle tuotteelle. Taulukossa on POD (Probability Of Detecton), FAR (False Alarm Ratio), F eli POFD (Probability Of False Detection) ja PSS (Peirce's Skill Score)

7.3 Virheen keskihajonta eri ennustepituuksilla


Tutkittiin kuinka ennustepituus vaikuttaa Harmonie-mallin natiivinäkyvyyden ja post-prosessoidun tuotteen toimintaan. Jaettiin asemien havainnot edellämainittuihin ICAO-luokkiin, ja laskettiin mallin ja havaintojen välinen virhe. Virheet jaettiin havaintojen mukaan ICAO-luokkiinsa, ja jokaiselle luokalle laskettiin keskihajonta. Keskihajonnan avulla saatiin tietoa kuinka keskittyneitä lasketut virheen arvot olivat.

Asemajoukkoon kuului yhteensä 13 asemaa, joille tehtiin keskiarvoistukset luokkajaon ja ennustepituuksien mukaan. Saatiin kuvat 7 ja 8, missä tummat sävyt kuvaavat 3-12h ennustepituuksia, ja kirkkaammat sävyt 15-24h pituuksia. Liitteessä A ja B ennustepituudet ovat eroteltuna asemakohtaisesti kummallekin eri tuotteelle. Liitteissä joiltakin asemilta puuttuu [0,150)-näkyvyysluokasta arvoja johtuen siitä, ettei havainnoista löytynyt yhtään näin huonon näkyvyyden tilannetta.


Suurimmat erot kuvien 7 ja 8 välillä löytyvät alle 3000m näkyvyyksistä, missä post-prosessoidulle tuotteelle virheen keskihajonta on paljon suurempi. Lisäksi kuvissa 7 ja 8 näkyy myös eri ennustepituuksien vaikutus etenkin alle 1500m näkyvyyksillä. Kaikkein parhaimpia tuloksia näyttäisi saavan 3h ja 6h ennustepituudet.

Kaikkien asemien osalta eniten eri ennustepituuksien välistä hajontaa näytti olevan huonojen näkyvyyksien tilanteissa. Se miksi eri näkyvyysluokilla on hyvinkin erilaisia keskihajonnan arvoja eri ennustepituuksilla, johtuu ainakin osaksi otantavirheestä. Havaintojen jakautuneisuus asemittain on esitetty taulukossa 11, missä näkyy kuinka paljon havaintoja on edustettuna eri luokista. Huonojen näkyvyyksien osalta otoskoko on hyvinkin niukka verrattuna hyvien näkyvyyksien puolelle, ja varsinkin Rovaniemen lentokentän osuus painottuu voimakkaasti. Hyvien näkyvyyksien tapauksissa eri ennustepituuksilla ei näytä olevan kovinkaan paljon hajontaa, koska otoskoko on suhteellisen suuri.

Taulukossa 12 on jaoteltu kaikkien asemien osalta kuukausittainen havaintojen jakautuneisuus. Huonoimmat näkyvyyshavainnot näyttäisivät painottuvan elo-syyskuulle. Tämä mitä ilmeisimmin painottuu Rovaniemen kentän (EFRO) mukaisesti, missä on myös taulukon 11 mukaan eniten havaittuja huonon näkyvyyden tilanteita.



Kuva 7: Kaikki ennustepituudet kaikilta asemilta keskiarvoistettuna luokittain ja ennustepituuksittain Harmonie-mallin näkyvyydestä.



Kuva 8: Kaikki ennustepituudet kaikilta asemilta keskiarvoistettuna luokittain ja ennustepituuksittain fysikaalisesti postprosessoidusta näkyvyydestä.

Station ID	[0-150)	[150-350)	[350-600)	[600-800)	[800-1500)	[1500-3000)	[3000-5000)	[5000-8000)	[8000-9999]	summa
EFRO	38	238	208	102	211	416	365	382	6774	8734
EFOU	0	15	39	43	73	110	182	270	8013	8745
EFKU	26	82	30	20	118	275	304	424	7402	8681
EFJY	12	94	73	38	94	220	366	412	7406	8715
EFTP	20	56	59	34	118	236	301	346	7538	8708
EFHK	0	38	47	28	92	184	292	420	7645	8746
ESPA	14	52	43	23	83	242	257	285	7540	8539
ESSA	7	36	50	18	57	163	184	391	7753	8659
ENG M	0	25	126	69	97	169	265	451	7477	8679
EKCH	9	29	22	19	75	193	329	503	7036	8215
EETN	4	41	23	19	91	165	392	477	7535	8747
EVRA	0	5	27	22	107	169	227	601	7599	8757
EIDW	8	45	48	17	104	363	506	651	6141	7883
summa	138	756	795	452	1320	2905	3970	5613	95859	111808

Taulukko 11: Havaintojen jakautuneisuus asemittain eri luokissa koko vuodelta. Alhaisemmille näkyvyyksille otoskoko on niukka.

Kuukausi	[0-150)	[150-350)	[350-600)	[600-800)	[800-1500)	[1500-3000)	[3000-5000)	[5000-8000)	[8000-9999]	summa
Tammikuu	9	85	146	61	251	572	650	884	6910	9568
Helmikuu	3	45	84	51	179	457	622	792	6416	8649
Maaliskuu	10	51	38	37	124	265	342	529	8182	9578
Huhtikuu	6	35	27	20	95	219	228	330	8336	9296
Toukokuu	9	23	19	7	26	68	100	137	9221	9610
Kesäkuu	5	19	12	4	12	21	75	161	8916	9225
Heinäkuu	2	9	7	3	9	37	93	172	8785	9117
Elokuu	13	34	21	11	31	31	86	184	8848	9259
Syyskuu	59	244	142	83	100	126	212	388	7906	9260
Lokakuu	8	67	83	36	75	179	342	501	8216	9507
Marraskuu	6	61	92	54	145	363	577	770	7152	9220
Joulukuu	8	83	124	85	273	567	643	765	6971	9519
summa	138	756	795	452	1320	2905	3970	5613	95859	111808


Taulukko 12: Havaintojen jakautuneisuus kuukausittain kaikilta asemilta ja koko vuodelta. Huonot näkyvyyshavainnot painottuvat elo-syyskuulle.

7.4 Virheen keskivirhe eri ennustepituuksilla


Virheen keskivirhe voitiin laskea havaintojen eri luokkien otoskoon avulla. Laskettiin jokaiselle asemalle luokkakohtaiset keskivirheet ennustepituuksien mukaan. Koko asemajoukosta tehtiin jälleen keskiarvoistukset luokkajaon ja ennustepituuksien mukaan. Kuvassa 9 näkyy Harmonie-mallin oman näkyvyyden ja kuvassa 10 fysikaalisesti postprosessoidun tuotteen näkyvyyden keskivirheet. Asemittain nämä ovat eroteltuna liitteessä C ja D.

Kuvista 9 ja 10 nähdään, että mitä alhaisemmissa näkyvyyksissä ollaan, sitä huonompi ennustettavuus on. Kuvia vertaamalla huomataan, että alle 1500m näkyvyyksissä Harmonie-mallin oma näkyvyys näyttäisi toimivan keskimäärin paremmin.

Selvä ero nähdään myös ennustepituuksien 3-12h (tummat sävyt) ja 15-24h (kirkkaat sävyt) välillä alle 800m näkyvyyksillä. Molemmille malleille keskivirheet ovat keskimäärin hieman pienempiä 3-12h ennustepituuksilla. Malli näyttäisi osaavan laskea tarkemmin lyhyemmillä ennustepituuksilla huonon näkyvyyden tilanteet paremmin.



Kuva 9: Kaikki ennustepituudet kaikilta asemilta keskiarvoistettuna luokittain ja ennustepituuksittain Harmonie-mallin näkyvyydestä.



Kuva 10: Kaikki ennustepituudet kaikilta asemilta keskiarvoistettuna luokittain ja ennustepituuksittain postprosessoidusta näkyvyydestä.

8 Analogiaennusteiden verifiointitulokset

8.1 Ennusteiden osuvuus kaikilla ennustepituuksilla

Analogiaennusteiden osuvuutta mitatessa kaikilla ennustepituuksilla käytettiin samankaltaista menettelytapaa kuin kappaleessa 7.1. Harmonie-mallin ja siitä fysikaalisesti post-prosessoidun tuotteen näkyvyysdataa rajattiin välille syyskuu-joulukuu, jotta tilastollisia ennusteita ja malleja pystyttiin vertailemaan keskenään.

Taulukoissa 13, 14 ja 15 on esitetty malli-havaintoparien vastaavuudet kaikilta ennustepituuksilta sekä kaikilta asemilta. Diagonaalilla sijaitsee lukuarvot täysin oikein menneistä ennusteista.

	Analogia									
Havainnot	[0-150)	[150-350)	[350-600)	[600-800)	[800-1500)	[1500-3000)	[3000-5000)	[5000-8000)	[8000-9999]	summa
[0-150)	58	106	50	14	35	26	27	28	292	636
[150-350)	159	684	302	124	151	188	216	243	1573	3640
[350-600)	52	432	270	130	248	304	288	286	1487	3497
[600-800)	43	152	182	75	144	217	160	154	902	2029
[800-1500)	41	223	204	169	377	549	487	481	2097	4628
[1500-3000)	39	257	280	190	469	1324	1567	1120	4432	9678
[3000-5000)	43	216	196	150	392	1655	2291	1875	7172	13990
[5000-8000)	44	256	245	155	425	1391	2701	2826	11206	19249
[8000-9999]	262	1460	1367	843	2106	5774	11322	16503	201759	241396
summa	741	3786	3096	1850	4347	11428	19059	23516	230920	298743

Taulukko 13: Ennusteiden osuvuus luokittain tilastomenetelmin tuotetulle mallin näkyvyydelle niin, että y-akselilla on havaittu näkyvyys ja x-akselilla mallin näkyvyys. Mukana ovat kaikki ennustepituudet sekä kaikkien asemien havainnot väliltä syyskuu-joulukuu. Diagonaalilla värjätyt luvut ovat täysin oikein menneistä ennusteista.


Piirrettiin taulukoiden avulla kuvat 11 ja 12, missä näkyy suhteelliset osuudet täysin oikein menneistä ennusteista sekä ennusteista, jotka ovat osuneet samaan luokkaan tai yhden luokan pieleen. Kuvista 11 ja 12 nähdään, että tilastomenetelmin tuotetut ennusteet (analogia) osuvat keskimäärin vain hieman huonoimmin samaan luokkaan tai enintään yhden luokan pieleen verattuna numeriisiin malleihin. Fysikaalisesti postprosessoitu näkyvyys näyttäisi pärjäävän keskimäärin parhaiten kummassakin vertailussa.

	Harmonie									
Havainnot	[0-150)	[150-350)	[350-600)	[600-800)	[800-1500)	[1500-3000)	[3000-5000)	[5000-8000)	[8000-9999]	summa
[0-150)	112	50	14	4	16	60	93	26	132	507
[150-350)	571	308	134	64	210	527	328	198	460	2800
[350-600)	542	277	125	76	207	559	293	159	389	2627
[600-800)	321	85	51	53	188	380	160	118	241	1597
[800-1500)	341	244	142	96	660	1152	311	249	408	3603
[1500-3000)	303	364	281	295	1199	2925	878	483	738	7466
[3000-5000)	284	457	347	222	1540	3853	1681	964	1434	10782
[5000-8000)	271	411	310	238	1105	4681	2946	2003	2803	14768
[8000-9999]	1432	1486	1121	728	2824	24054	27435	29801	100004	188885
summa	4177	3682	2525	1776	7949	38191	34125	34001	106609	233035


Taulukko 14: Ennusteiden osuvuus luokittain Harmonie-mallin näkyvyydelle niin, että y-akselilla on havaittu näkyvyys ja x-akselilla mallin näkyvyys. Mukana ovat kaikki ennustepituudet sekä kaikkien asemien havainnot väliltä syyskuu-joulukuu. Diagonaalilla värjätyt luvut ovat täysin oikein menneitä ennusteita.

	Postprosessoitu									
Havainnot	[0-150)	[150-350)	[350-600)	[600-800)	[800-1500)	[1500-3000)	[3000-5000)	[5000-8000)	[8000-9999]	summa
[0-150)	0	124	31	9	4	19	35	35	250	507
[150-350)	0	478	449	98	139	269	209	202	956	2800
[350-600)	0	437	390	136	182	226	218	208	830	2627
[600-800)	0	194	189	98	182	204	134	105	491	1597
[800-1500)	0	369	317	172	791	612	296	215	831	3603
[1500-3000)	0	425	385	241	1262	2130	929	608	1486	7466
[3000-5000)	0	475	508	322	1100	2391	1759	1353	2873	10781
[5000-8000)	0	417	403	292	1088	2536	2388	2075	5569	14768
[8000-9999]	0	1407	1874	1092	3505	8061	9950	13907	149077	188873
summa	0	4326	4546	2460	8253	16448	15918	18708	162363	233022

Taulukko 15: Ennusteiden osuvuus luokittain postprosessoidun tuotteen näkyvyydelle niin, että y-akselilla on havaittu näkyvyys ja x-akselilla mallin näkyvyys. Mukana ovat kaikki ennustepituudet sekä kaikkien asemien havainnot väliltä syyskuu-joulukuu. Diagonaalilla värjätyt luvut ovat täysin oikein menneitä ennusteita.



Kuva 11: Osumatarkkuudet eli kaikkien havaintoasemien lasketut suhteet siitä, kuinka monta prosenttia ennusteista osuu täysin oikeaan luokkaan havaintojen kanssa välillä syyskuu-joulukuu. Sininen käyrä kuvaa Harmonie-mallin omaa näkyvyyttä, punainen fyysikaalisesti postprosessoitua tuotetta ja vihreä tilastomenetelmin laskettua näkyvyyttä. Vaakaviivoilla on keskiarvo luokkakohtaisista arvoista.



Kuva 12: Osumatarkkuudet eli kaikkien havaintoasemien lasketut suhteet siitä, kuinka monta prosenttia ennusteista osuu täysin oikeaan luokkaan tai yhden luokan pieleen havaintojen kanssa välillä syyskuu-joulukuu. Sininen käyrä kuvaa Harmonien omaa näkyvyyttä, punainen fysikaalisesti postprosessoitua tuotetta ja vihreä tilastomenetelmin laskettua näkyvyyttä. Vaakaviivoilla on keskiarvo luokakohtaisista arvoista.

8.2 Binääriennusteet

Analogiaennusteille, Harmonielle sekä fysikaalisesti postprosessoidulle tuotteelle laskettiin verifointisuureet aivan kuten kappaleessa 7.2. Näiden ennusteiden osalta rajauduttiin jälleen syys-joulukuu -väliselle akselille. Taulukossa 16 on laskettu jokaiselle eri mallille POD, FAR, POFD sekä PSS kontingenssitaulukon (taulukko 9) avulla.

Huomataan, että analogiaennusteet pärjäävät suhteellisen hyvin verrattuna Harmonieen ja fysikaalisesti postprosessoituun tuotteeseen. Lähes kaikilla luokilla analogiaennusteiden väärin hälytysten suhde (FAR) on kaikista pienin, joka tarkoittaa että ”kyllä”-ennuste toteutui muita malleja useammin.

Yli 3000m näkyvyyksillä analogiaennusteiden osumatarkkuudet ovat muita vertailussa olevia malleja hieman paremmat, mutta alle 3000m näkyvyyksillä analogiaennusteiden osumatarkkuudet ovat pääasiassa selvästi huonompia. Tämä nähdään myös kuvasta 11. Mitä useammin ilmiö jää ennustamatta, niin sitä huonommin malli palvelee käyttäjää.

LUOKKA	SUURE	ANALOGIA	HARMONIE	POSTPROSESSOITU
0-150	POD	0.091194969	0.2209072978	0
	FAR	0.921727395	0.9731864975	-
	POFD	0.002291124	0.0174817656	0
	PSS	0.088903845	0.2034255322	0
150-350	POD	0.187912088	0.11	0.1707142857
	FAR	0.81933439	0.9163498099	0.8895053167
	POFD	0.010547182	0.0149030902	0.0167421543
	PSS	0.177364906	0.0950969098	0.1539721314
350-600	POD	0.077209036	0.0475827941	0.1484583175
	FAR	0.912790698	0.9504950495	0.9142102948
	POFD	0.009768643	0.0107966584	0.0184807211
	PSS	0.067440394	0.0367861356	0.1299775964
600-800	POD	0.036964022	0.033187226	0.0613650595
	FAR	0.95945946	0.9701576577	0.9601626016
	POFD	0.006202195	0.007832281	0.0106847369
	PSS	0.030761827	0.0253549451	0.0506803226
800-1500	POD	0.081460674	0.1831806828	0.2195392728
	FAR	0.913273522	0.9169706881	0.9041560645
	POFD	0.014091956	0.0336272081	0.0343574892
	PSS	0.067368718	0.1495534747	0.1851817837
1500-3000	POD	0.136805125	0.3917760514	0.2852933298
	FAR	0.884144207	0.9234112749	0.8705009728
	POFD	0.037121947	0.1685529661	0.068817349
	PSS	0.099683178	0.2232230853	0.2164759808
3000-5000	POD	0.163759828	0.1559079948	0.1631574065
	FAR	0.879794323	0.9507399267	0.8894961679
	POFD	0.065163998	0.1802534571	0.0724805348
	PSS	0.065163998	-0.024345462	0.0906768717
5000-8000	POD	0.146812821	0.1356310943	0.1405065005
	FAR	0.879826501	0.9410899679	0.8890848835
	POFD	0.086785093	0.9410899679	0.0901136647
	PSS	0.060027729	-0.070296119	0.0503928359
8000-9999	POD	0.835800925	0.5294438415	0.7892975703
	FAR	0.126281829	0.0619553696	0.0818289881
	POFD	0.508500881	0.149603624	0.3009354685
	PSS	0.327300044	0.3798402175	0.4883621018

Taulukko 16: Verifiointisuureet Analogiaennusteille, Harmonielle ja fysikaalisesti post-prosessoidulle tuotteelle rajattuna ajanjaksolle syyskuu-joulukuu. Taulukossa on POD (Probability Of Detecton), FAR (False Alarm Ratio), F eli POFD (Probability Of False Detection) ja PSS (Peirce's Skill Score).


8.3 Virheen keskihajonta eri ennustepituuksilla

Tässä käytettiin samaa menetelmää kuin kappaleessa 7.3. Laskettiin keskihajonnan keskiarvot kaikille asemille luokkarajojen ja ennustepituuksien mukaan ja piirrettiin kuva 13. Eri ennustepituuksien välillä on keskimäärin selvästi enemmän hajontaa kuin Harmoniemallin ja fysikaalisesti postprosessoidun tuotteen vastaavissa tapauksissa, vaikkakin tämä tarkastelu edustaa vain neljän kuukauden ajanjaksoa. Varsinkin alle 1500m näkyvyyksillä ennustepituuksien välinen hajonta on suurta. Yllättäen ennustepituuden vaikutus ei juurikaan ole nähtävissä.

Havaintojen jakautuneisuus välillä syyskuu-joulukuu on esitetty taulukossa 17, jossa edelleen korostuu Rovaniemen lentokentän osuus huonojen näkyvyyksien osalta. Keskihajontaa ei pystytty laskemaan mikäli havaintoja oli saatavilla vain yksi tai vähemmän jostakin luokasta. Liitteessä E keskihajonnat on eritelty asemakohtaisesti. Kööpenhaminan lentoaseman (EKCH) epäjatkuvuuskohta [150,350) ja [600-800) välillä on jätetty piirtämättä.

Station ID	[0-150)	[150-350)	[350-600)	[600-800)	[800-1500)	[1500-3000)	[3000-5000)	[5000-8000)	[8000-9999]	summa
EFRO	20	178	152	71	118	219	163	193	1802	2916
EFOU	0	12	31	31	39	49	87	117	2554	2920
EFKU	22	55	24	11	63	128	157	198	2237	2895
EFJY	8	69	47	25	47	98	199	205	2209	2907
EFTP	16	36	32	20	60	111	149	153	2323	2900
EFHK	0	15	20	11	29	58	114	183	2490	2920
ESPA	13	40	25	14	43	106	124	142	2345	2852
ESSA	1	22	28	11	32	74	88	154	2485	2895
ENGMI	0	3	50	38	42	62	110	166	2427	2898
EKCH	1	4	1	3	20	44	93	131	2355	2652
EETN	0	9	12	8	27	59	148	217	2445	2925
EVRA	0	1	3	9	44	68	91	268	2443	2927
EIDW	0	11	15	6	29	158	249	296	2122	2886
summa	81	455	440	258	593	1234	1772	2423	30237	37493

Taulukko 17: Havaintojen jakautuneisuus eri luokissa syyskuu-joulukuu -väliselle ajalle. Alhaisemmille näkyvyyksille otoskoko on niukka.




Kuva 13: Kaikki ennustepituudet kaikilta asemilta keskiarvoistettuna luokittain ja ennustepituuksittain tilastollisesti tuotetusta näkyvyydestä välillä syys-joulukuu.

8.4 Virheen keskivirhe eri ennustepituuksilla

Analogiaennusteille laskettiin keskivirheet ennustepituuksittain samalla tavalla kuten kapaleessa 7.4. Asemakohtaiset keskivirheet löytyvät liitteestä F.

Kun tehdään keskiarvoistus kaikista asemista luokittain ja ennustepituuksittain, saadaan kuvan 14 mukainen jakauma. Kuvasta 14 voidaan yleistää, että havaintoja ei ole tarpeeksi kattavasti alle 800m näkyvyysluokista, koska ennustepituuksien välistä hajontaa on hyvin paljon. Ennustepituuksien välillä karkeasti ottaen parhaiten näyttäisivät pärjäävän pisimmät ennustepituudet (15-24h). Keskivirhe näyttäisi olevan paljon suurempi verrattuna numeeristen mallien vastaaviin tuloksiin, mutta kuvat eivät ole täysin vertailukelpoisia keskenään johtuen eri ajanjaksosta.



Kuva 14: Kaikki ennustepituudet kaikilta asemilta keskiarvoistettuna luokittain ja ennustepituuksittain tilastollisesti tuotetusta näkyvyydestä. Tummat sävyt kuvaavat 3-12h ennustepituuksia ja kirkkaat 15-24h ennustepituuksia.

9 Yhteenveto

Työssä havaittiin, että Harmonie-mallin ja siitä fysikaalisesti postprosessoidun tuotteen välillä erot korostuvat etenkin huonojen näkyvyysien tapauksissa. Käytettävissä oleva vuoden mittainen verifointijakso oli suhteellisen lyhyt, koska alle 150m näkyvyyshavainnot oli pääpiirteissään hyvin niukasti, ja joiltain asemilta ei ollenkaan. Jotta verifointia olisi pystytty tekemään kattavammin, olisi isompi datamäärä ollut eduksi. Analogiaennusteet puolestaan tuotettiin tarkoituksenmukaisesti syksyn ja alkutalven puolelle, koska tämä ajanjakso on lentosään ennustamisessa haastellinen. Tässä työssä ei tutkittu tilastollisia merkitsevyyseroja aineistojen välillä, joten erot voivat johtua myös sattumasta.

Huomattiin, että yli 8km näkyvyyksillä sekä Harmonie että fysikaalisesti postprosessoitu tuote pyrkivät selvästi aliennustamaan tapahtumien lukumäärää. Toisaalta alle 8km näkyvyyksillä kumpikin malli yliennustaa lukumäärällisesti, mikäli alle 150m näkyvyyydet jätetään tarkastelusta pois. Postprosessoitu tuote yliennustaa lukumäärällisesti voimakkaammin [150,1500m)-luokkien välillä, ja toisaalta Harmonie yliennustaa voimakkaammin luokkien [1500,8000m) välisillä näkyvyyksillä. Alle 150m näkyvyyksillä kummatkin mallit toimivat lähes yhtä huonosti.

Ennusteiden osuvuuksia verratessa havaintoihin huomattiin, että otoskoon kasvattaminen luokkien [150,1500m)-välillä kasvatti fysikaalisesti postprosessoidulle tuotteelle ennusteiden osuvuutta (POD). Binääriennusteiden kautta havaittiin, että postprosessoidulle tuotteelle myös väärin hälytysten suhde (FAR) oli ko. luokkavälillä hieman pienempi. Yli 3000m näkyvyyksillä Harmonien ja postprosessoidun tuotteen osumatarkkuuksien välillä mittavia eroja ei ollut. Suurin ero havaittiin siinä, että Harmoniella ”kyllä”-ennuste jäi toteutumatta postprosessoitua tuotetta hieman useammin lähes kaikilla luokkaväleillä.

Ennustepituuksien keskimääräistä keskihajontaa ja keskivirhettä verratessa osuvuuksiin, tulokset osoittautuivat päinvastaisiksi alle 1500m näkyvyyksillä. Tämä voi mahdollisesti johtua siitä, että postprosessoidulle tuotteelle ennusteiden osuvuuksista luokille löytyy arvoja, jotka poikkeavat suhteellisen paljon ennusteluokasta, ja taas niitä, jotka osuvat lähes samaan luokkaan. Tällöin virheen keskihajonta ja keskivirhe on verrattaen suuri, vaikka ennusteiden osuvuuksissa pärjätäänkin ihan hyvin. Toisaalta ennusteiden osuvuudet ovat Harmonielle alle 1500m näkyvyyksillä huonompia, vaikka keskihajonta ja

-virhe on pienempi. Tämä voi taas mahdollisesti johtua siitä, että Harmonie pyrkii ennustamaan keskivertaisesti. Poikkeamat ovat pienempiä, mutta osuvuuksiltaan kuitenkin liian vääriä. Postprosessoidut ennusteet ovat siis äärevämpiä.

Verifointituloksista havaittiin myös, että ennustepituuden kasvattamisella 3:sta 24:n tuntiin ei ollut keskimäärin merkittävää vaikutusta Harmonien- tai fysikaalisesti postprosessoidun tuotteen toimintaan. Virheen keskivirhettä tarkastellessa alle 800m näkyvyyksillä pientä hajontaa oli 3-12h että 15-24h ennustepituuksien välillä. Tämä voi johtua joko sattumasta tai mallien kyvystä ennustaa tarkemmin huonon näkyvyyden tilanteita lyhyemmillä ennustepituuksilla.

Tilastomenetelmin tuotettuja analogiaennusteita verifioitiin syys-joulkuu -väliseltä ajalta. Analogiaennusteet pärjäsivät tässä vertailussa kohtuullisesti. Lähes kaikilla luokilla analogiaennusteiden väärien hälytysten suhde (FAR) oli kaikista pienin, joka tarkoittaa, että ”kyllä”-ennuste toteutui Harmonieta ja fysikaalisesti postprosessoitua tuotetta useammin. Yli 3000m näkyvyyksillä analogiaennusteiden osumatarkkuudet olivat hieman vertailussa olevia malleja parempia, mutta alle 3000m näkyvyyksillä huonompia. Mitä useammin ilmiö jää ennustamatta, niin sitä huonommin malli palvelee käyttäjää.

Verifointijakso oli myös suhteellisen pieni, vaikkakin se edusti tärkeimpää osaa vuodesta. Ennustepituuksien välinen hajonta oli analogiaennusteilla keskimäärin suurta alle 1500 metrin näkyvyyksillä, sekä keskihajonnan ja keskivirheen arvot olivat suuria. Yllättäen ennustepituuksien vaikutus ei ollut juurikaan nähtävissä. Tällaiseen tulokseen osaltaan vaikuttaa myös lyhyt havaintojakso ja niukat havainnot huonoista näkyvyysluokista. Parametrien painotuksia eri tavalla valitsemalla olisi mahdollisesti pystytty saamaan parempia ennustetuloksia, mutta niiden herkkyytstarkastelu olisi vienyt suhteettoman paljon aikaa.

Virhettä ja epävarmuutta tuloksiin on saattanut tulla sekä manuaalisten että automaattisten näkyvyyshavaintojen sekoittamisesta. Tätä ei voitu välttää, koska automaattisia havaintoja ei tallenneta erikseen omaan tietokantaansa vuorokauden ympäri. Havaintoaineistossa olisi ollut valtavia puutteita, mikäli verifointia olisi suoritettu pelkästään automaattihavaintoihin pohjautuen. Isompi datamäärä oli täysi välttämättömyys myös analogiaennusteiden laskennan kannalta.

Automaattisista havaintomittauksista on mahdollisesti kertynyt virhettä dataan, kos-

ka näkyvyysanturi ei välttämättä osaa mitata sellasia ilmiöitä, mitä havainnontekijä pystyy. Havainnon pistemäisyyden vuoksi esimerkiksi puoliksi lentokentän peittävä sumu saattaa jäädä automaattihavainnoissa kokonaan mittaamatta. Talvikaudella myös kunnossapitoaurojen tai tuulen nostattama lumi sekä ilmassa leijailevat jääkiteet tuottavat haasteita näkyvyysantureille. Varasinkin jääkiteet sirottavat säteilyä niin hyvin, että automaattit havaitsevat heikompia näkyvyyksiä verrattuna todellisuuteen.

Harmonie-mallissa näkyvyys lasketaan noin 10m korkeudella, kun taas lentoasemilla mittarit mittaavat lukeman noin 2m korkeudella. Malleilta voi siis jäädä huomiotta aivan maanpinnalla tapahtuvat ilmiöt, kuten aivan kiitotien tasalla leijaileva sumu. Muutaman metrin ero voi tuottaa jonkinlaista virhettä lopputuloksiin, mutta suurista virheistä ei voida puhua, koska dominoivana tekijänä on kuitenkin mallin kyky ylipäättään ennustaa tämänkaltaisia ilmiöitä.

Kaikkiaan tulokset osoittavat, että tulevaisuudessa näkyvyysennusteita joudutaan vielä kehittämään runsaasti mallien osalta. Analogiaennusteita olisi mielenkiintoista kehittää vielä eteenpäin hybridiennusteiksi, jolloin ennusteet eivät olisi pelkkien tilastojen varassa vaan ennustamisen apuna olisivat myös numeeriset mallit. Kenties analogiaennusteita pystyttäisiin hyödyntämään jo tällaisenaan lentosääennustamisessa esimerkiksi yli 5000m näkyvyyksillä. Kehittämistä kuitenkin vielä riittää niin tilastollisesti kuin fysikaalisesti postprosessoitujen menetelmien osalta.

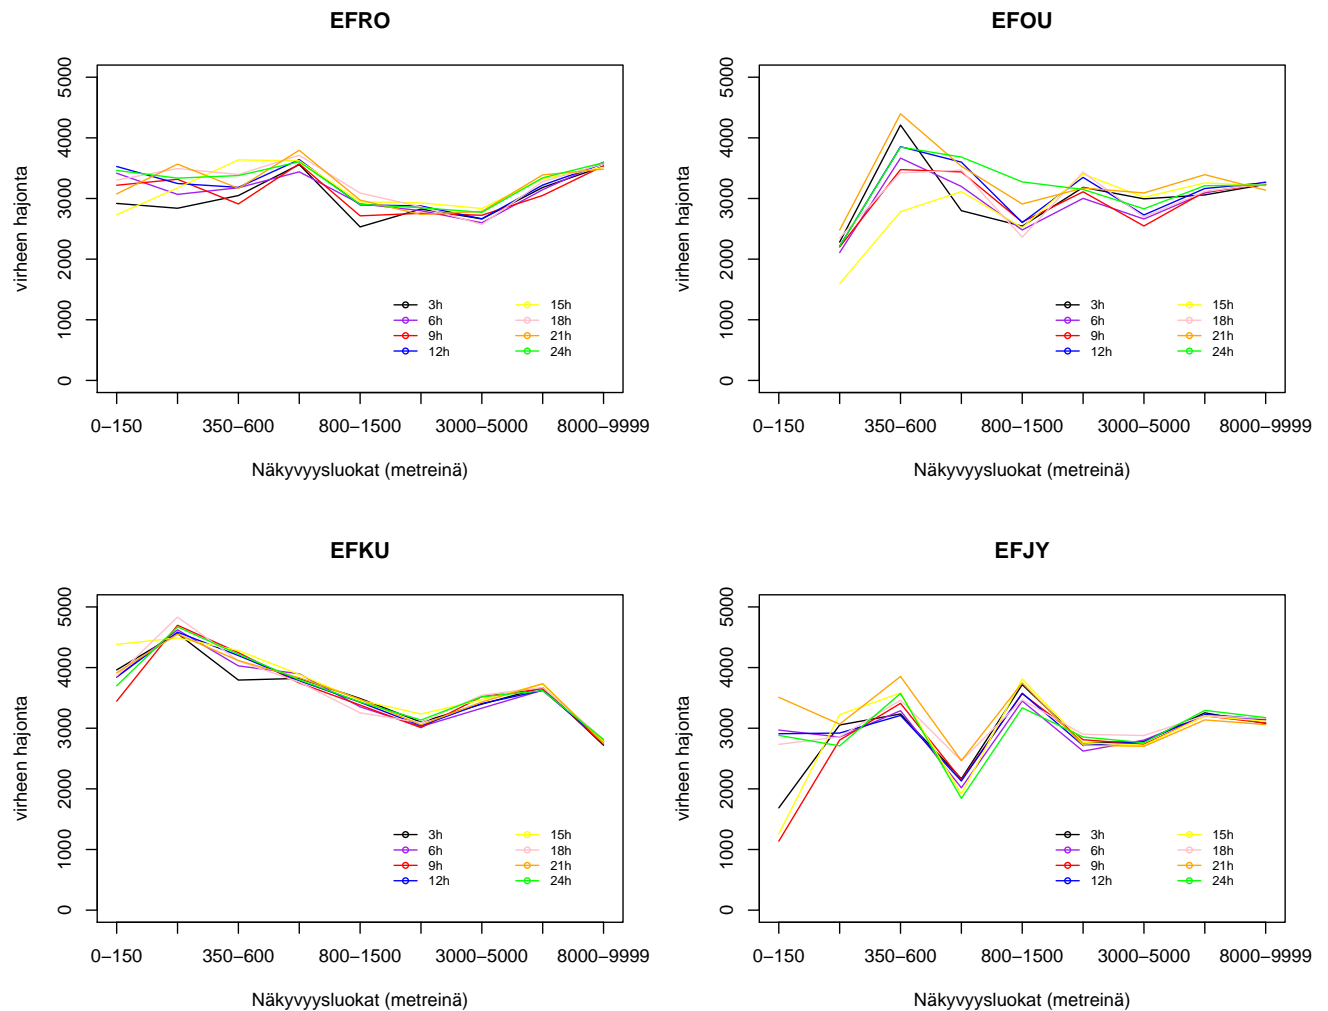
10 Viitteet

- [1] Annex 3, 19th edition, 2016: Meteorological Service for International Air Navigation. *International Civil Aviation Organization*, Chapter 4: Meteorological observations and reports & Chapter 6: Forecasts & Appendix 5: Technical specifications related to forecasts.
- [2] Bengtsson, L., U. Andrae, T. Aspelien, Y. Batrak, J. Calvo, W. De Rooy, E. Gleeson, B. Hansen-Sass, M. Homleid, M. Hortal, K-I. Ivarsson, G. Lenderink, S. Niemela, K. Pagh Nielsen, J. Onvlee, L. Rontu, P. Samuelsson, D. Santos Munoz, A. Subias, S. Tijm, V. Toll, X. Yang, M. Odegaard Koltzow, 2017: The HARMONIE-AROME Model Configuration in the ALADIN-HIRLAM NWP System. *American Meteorological Society*, **145**, s. 1919-1935.
- [3] Blanco Sequeiros, A., M. Astevirta, T. Erkkilä, M. Heinonen, M. Jokimäki, T. Lassila, I. Snellman, R. Pukkila ja K. Österberg: New TAF verification, Version 1.41. Nordic. Saatavilla osoitteesta: http://lentosaa.fmi.fi/nordictafverif/tafverif/New_TAF_verification_scheme_nordic_version.pdf
- [4] Fu, Q., 1996: An accurate parameterization of the solar radiative properties of cirrus clouds for climate models. *Journal of Climate*, **9**, s. 2058–2082.
- [5] Groff, L. S., J. M. Price, 2006: General aviation accidents in degraded visibility: a case control study of 72 accidents. *Aviation, Space, and Environmental Medicine*, **77**, s. 1062-1067
- [6] Hansen, B., 2007: A Fuzzy Logic-Based Analog Forecasting System for Ceiling and Visibility. *Weather and forecasting*, **22**, s. 1319-1330.
- [7] IFS Documentation – Cy43r1 Operational implementation, 2017: PART IV: Physical Processes, Chapter 2: Radiation & Chapter 3: Turbulent transport and interactions with the surface. *European Centre for Medium-Range Weather Forecasts*, s. 26-27, 33-58.





- [8] Jolliffe, I. T., D. B. Stephenson, 2003: Forecast Verification: A Practitioner’s Guide in Atmospheric Science, 2nd Edition. *A John Wiley & Sons, Ltd., Publication.*
- [9] Lentosääpalvelut Suomessa, 2017. Saatavilla osoitteesta:
http://ilmailusaa.fi/pdf/Lentosaapalvelut_Suomessa_VIII_2017_www.pdf
Ilmatieteen laitos, s. 4-13
- [10] Koschmieder, H., 1924: Theorie der horizontalen sichtweite. *Beitrage zur Physik der freien Atmosphere*, **12**, 171–181.
- [11] Martin G. M., D. W. Johnson, A. Spice, 1994: The measurement and parameterization of effective radius of droplets in warm stratocumulus clouds. *Journal of the Atmospheric Sciences*, **51**, s. 1823–1842.
- [12] Nielsen, K. P., E. Gleeson, L. Rontu, 2014: Radiation sensitivity tests of the HAR-MONIE 37h1 NWP model. *Geoscientific Model Development*, **7**, s. 1433–1449.
- [13] Rudack, D. E., J. E. Ghirardelli, 2010: A Comparative Verification of Localized Aviation Model Output Statistics Program (LAMP) and Numerical Weather Prediction (NWP) Model Forecasts of Ceiling Height and Visibility. *Weather and Forecasting*, **25**(4), s. 1161-1178.
- [14] Sun, Z., 2001: Reply to comments by Greg M. McFarquhar on ‘Parametrization of effective sizes of cirrus-cloud particles and its verification against observations’ *Q. J. R. Meteorological Society*, **127**, s. 267-271.
- [15] Sun, Z., L. Rikus, 1999: Parametrization of effective sizes of cirrus-cloud particles and its verification against observations. *Q. J. R. Meteorological Society*, **125**, s. 3037-3055.
- [16] Tegen, I., P. Hollrig, M. Chin, I. Fung, D. Jacob, J. Penner, 1997: Contribution of different aerosol species to the global aerosol extinction optical thickness: Estimates from model results. *Journal of Geophysical Research*, **102**, s. 23895-23915.
- [17] Tuba, Z., Z. Bottyan, 2017: Fuzzy logic-based analogue forecasting and hybrid modelling of horizontal visibility. *Meteorology and Atmospheric Physics*, **130**, s. 265-277.

- [18] Weather Sensor FD12P, 2002: User Guide. *Vaisala Oyj*, s. 21-22, 95-96, 105-106.
- [19] World Meteorological Organization, 2014 edition: Guide to Meteorological Instruments and Methods of Observation, Chapter 9: Measurement of Visibility. *World Meteorological Organization*, s. 291-309.

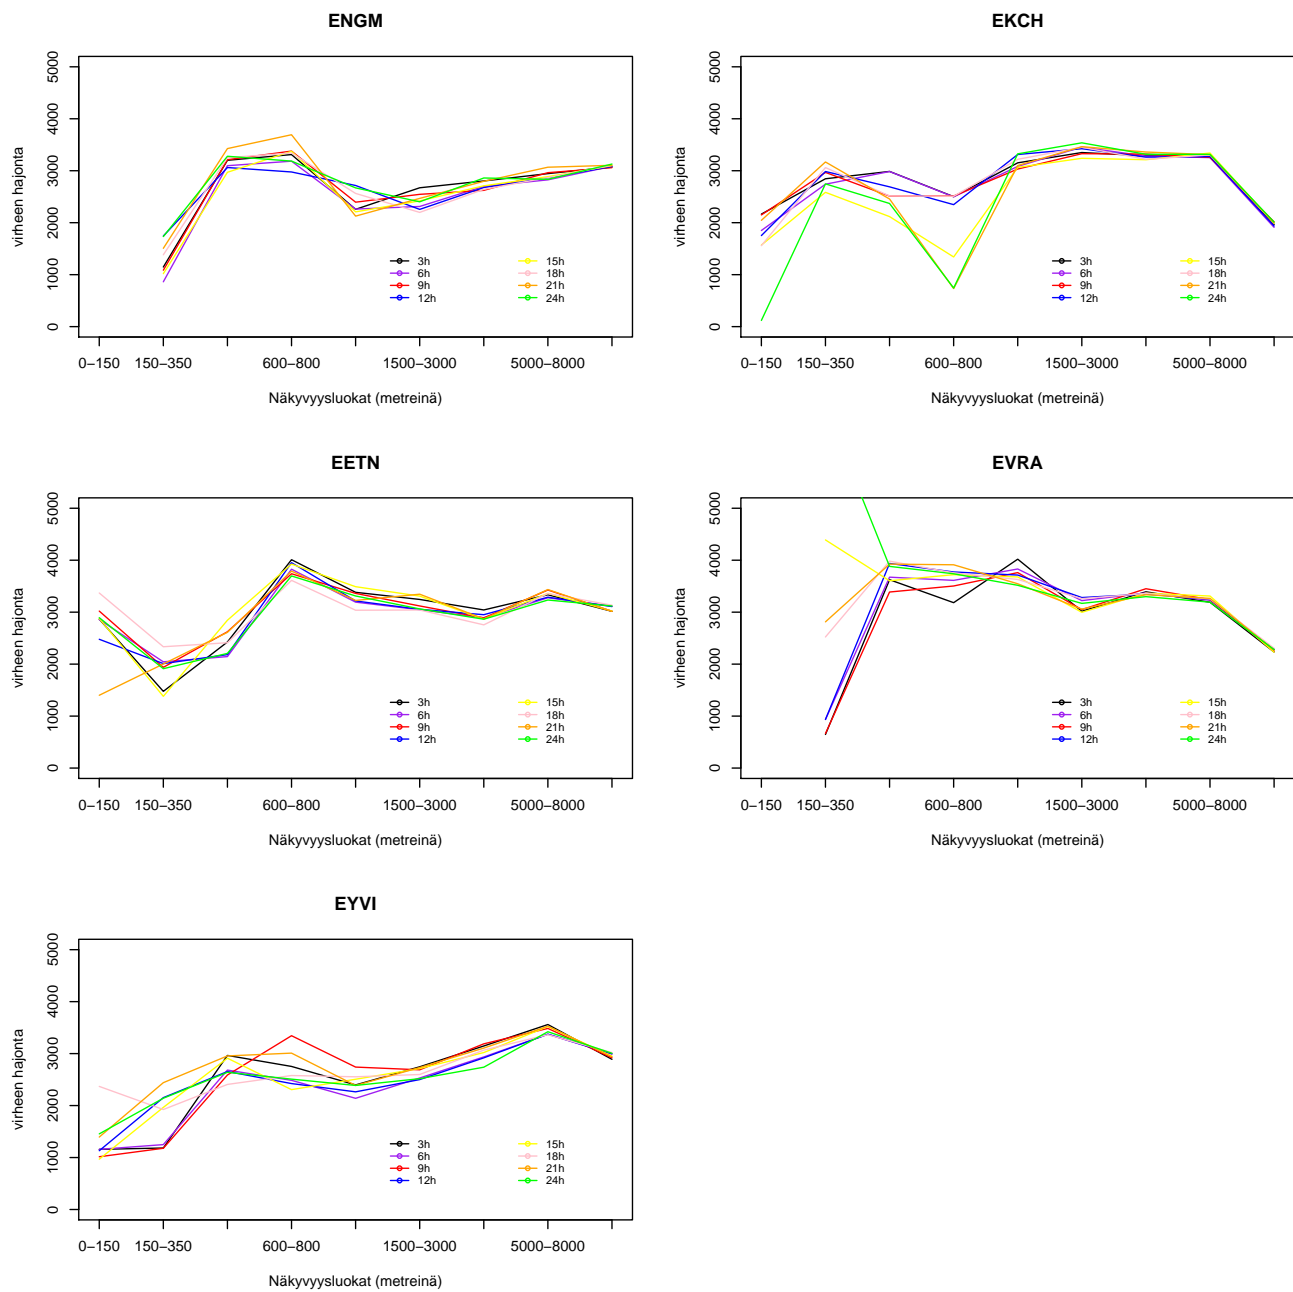
A Virheen keskihajonta eri ennustepituuksilla, Harmo- nie



Kuva A.1: Rovaniemen, Oulun, Kuopion ja Jyväskylän kentät ennustepituuksittain

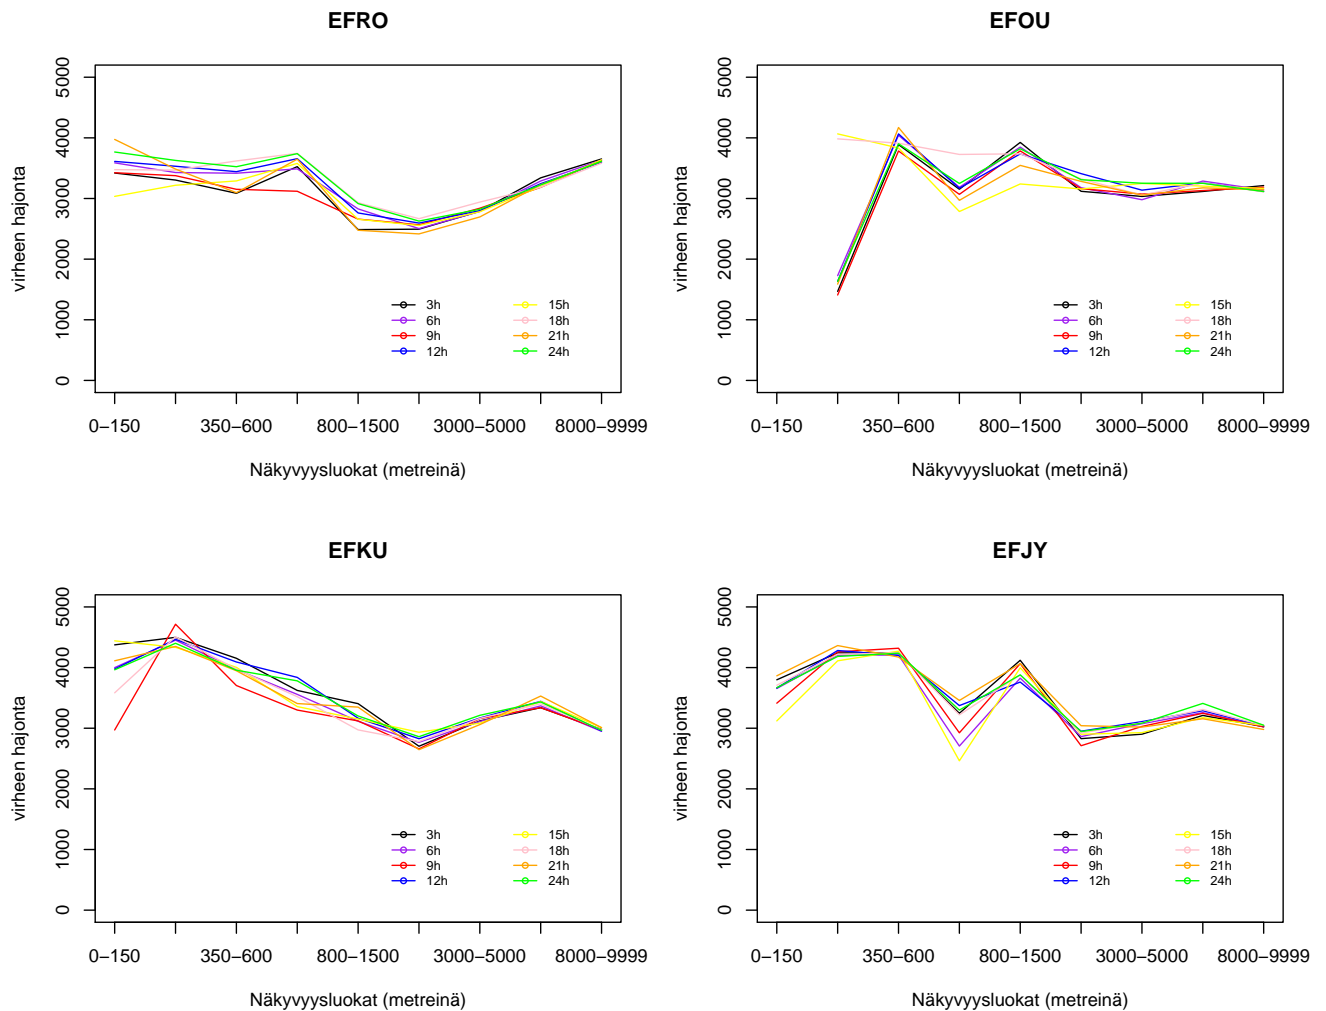


Kuva A.2: Tampereen, Helsinki-Vantaan, Lulea-Kallaxin ja Arlandan kentät ennustepi-
tuuksittain

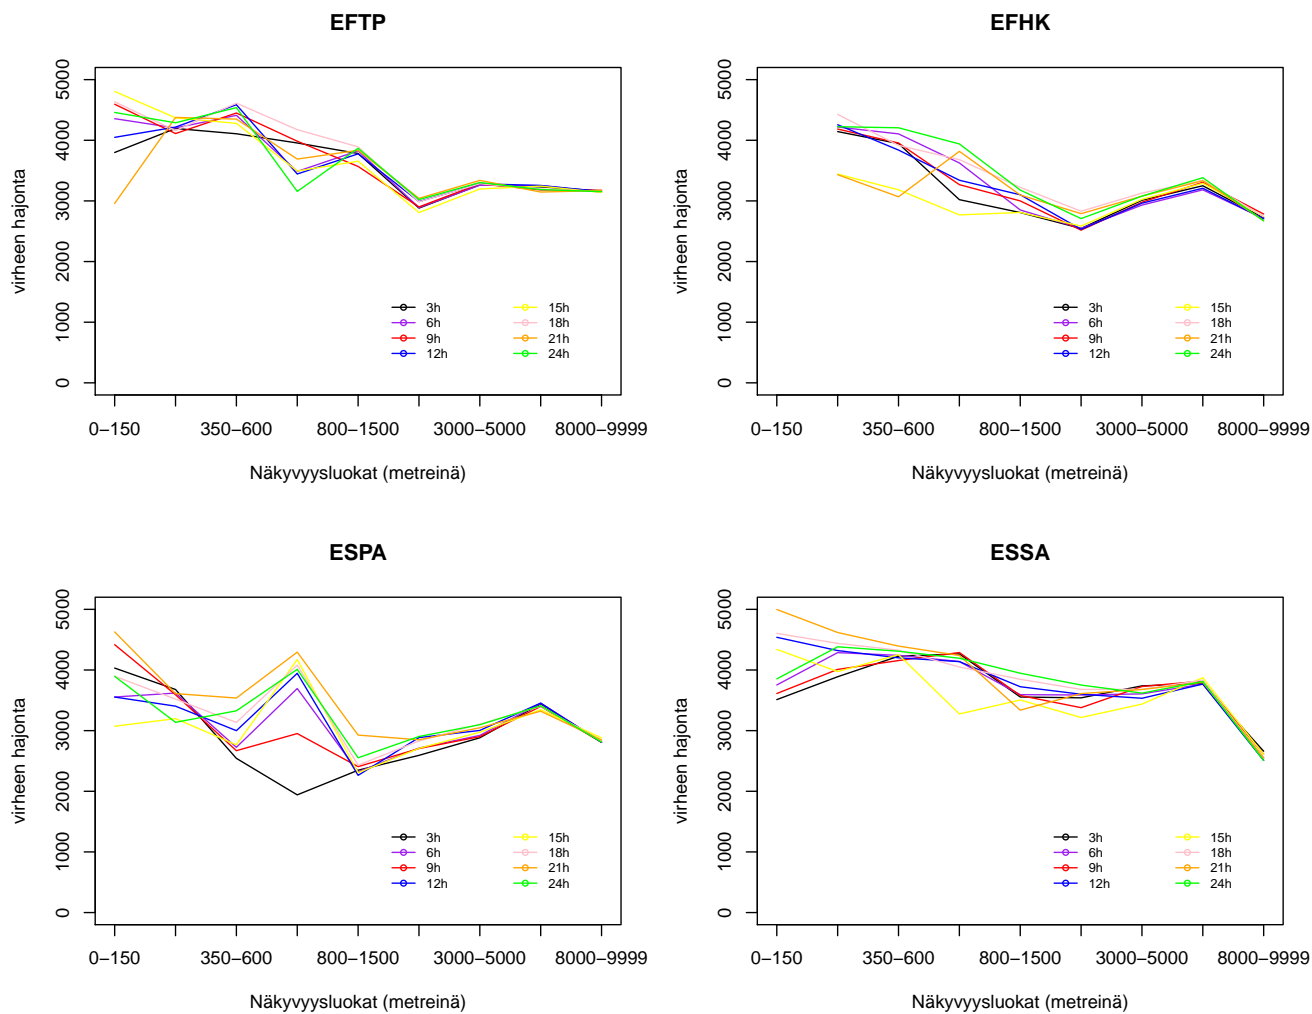


Kuva A.3: Oslon, Kööpenhaminan, Tallinnan, Riian ja Vilnan kentät ennustepituuksittain






B Virheen keskihajonta eri ennustepituuksilla, fysikaalisesti postprosessoitu tuote



Kuva B.1: Rovaniemen, Oulun, Kuopion ja Jyväskylän kentät ennustepituuksittain

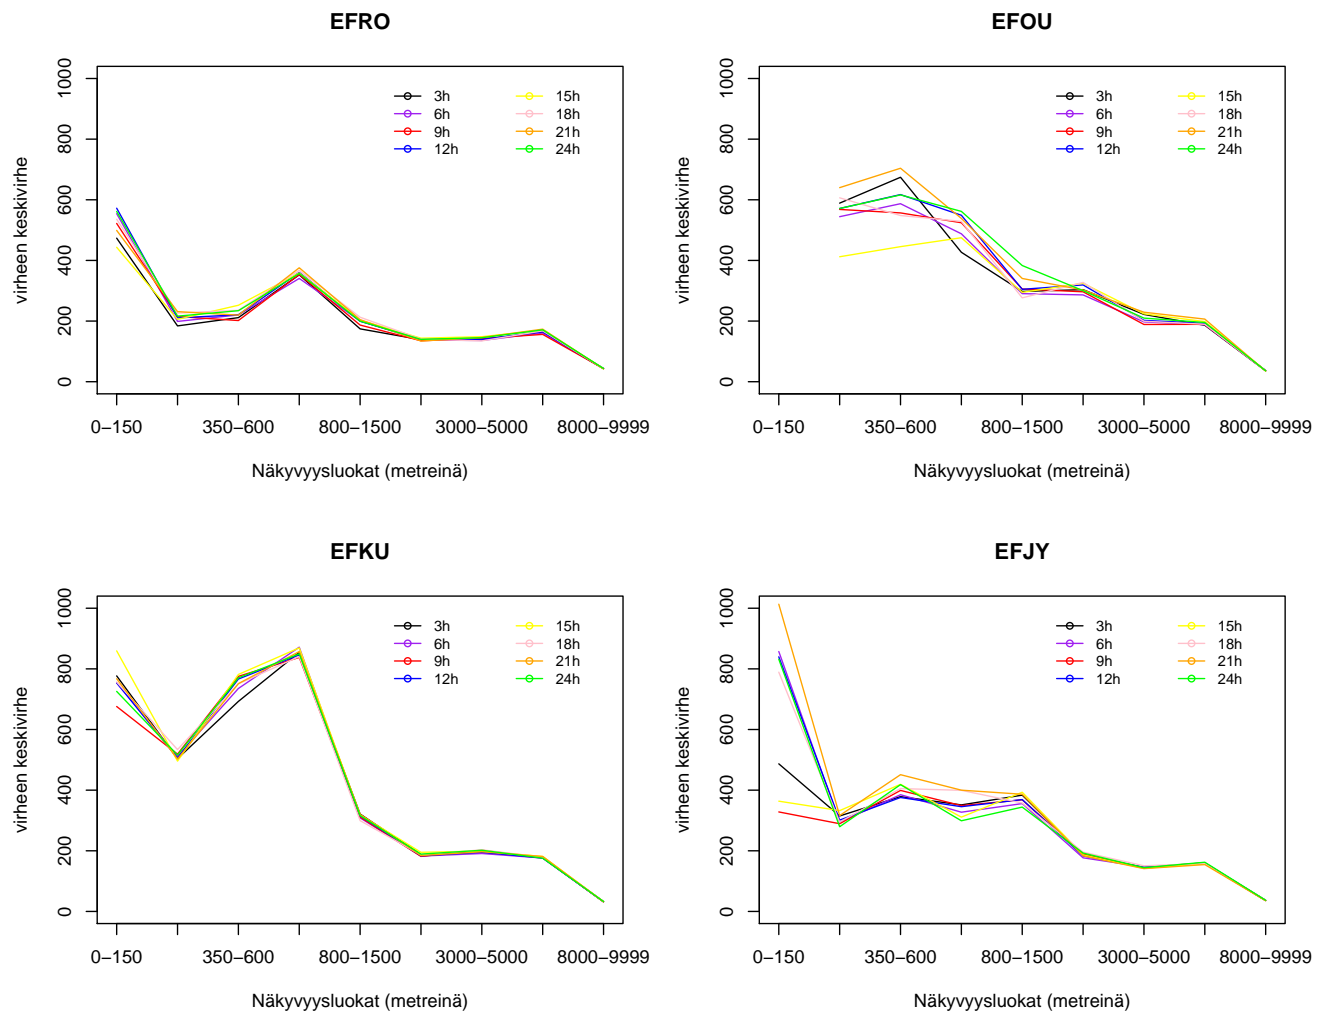


Kuva B.2: Tampereen, Helsinki-Vantaan, Lulea-Kallaxin ja Arlandan kentät ennustepi-
tuuksittain

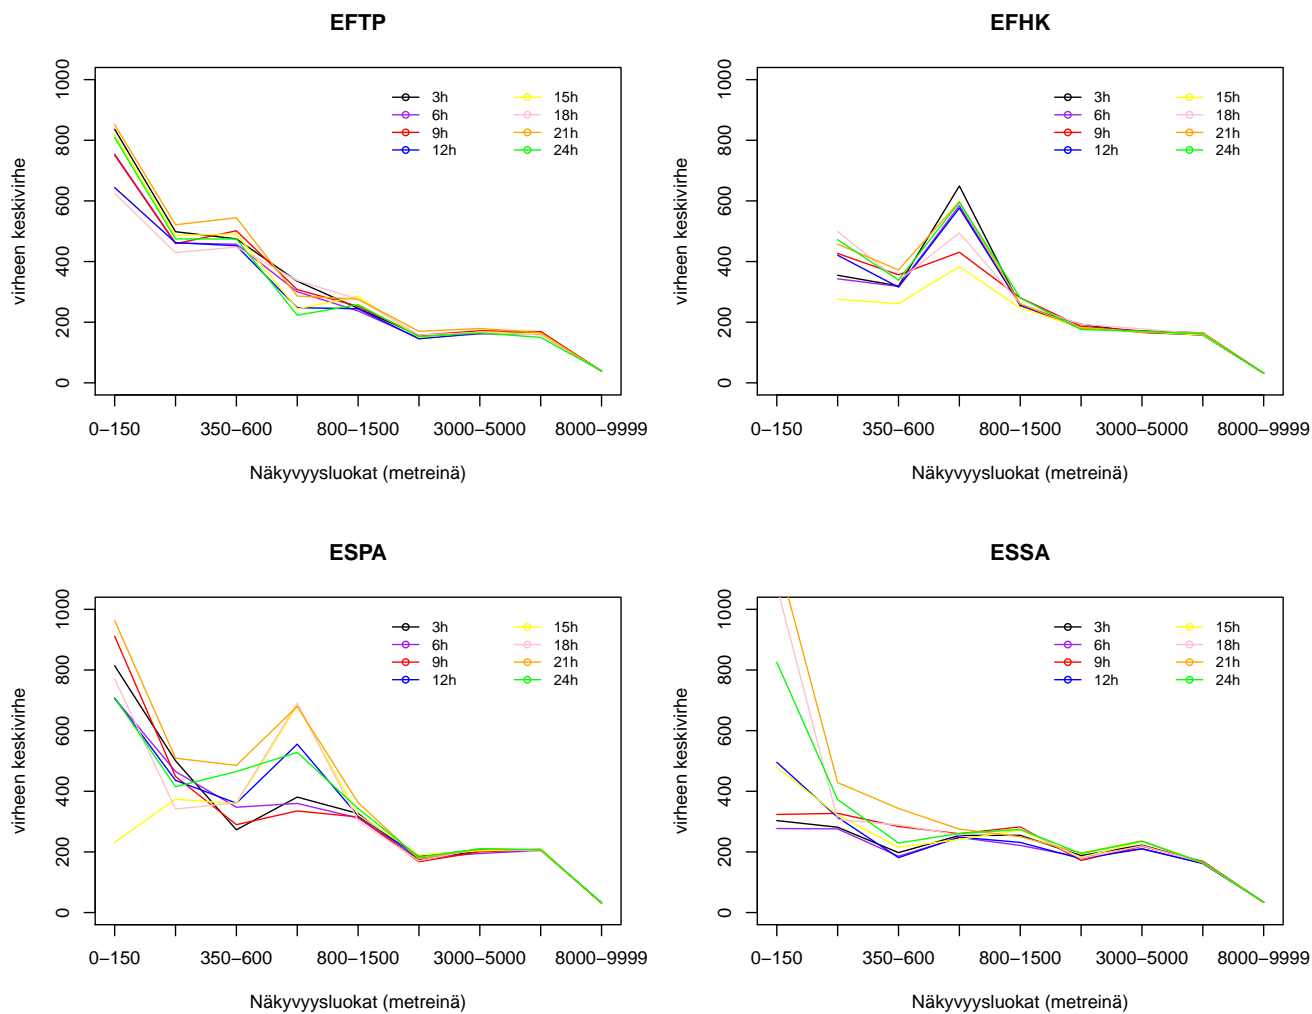


Kuva B.3: Oslon, Kööpenhaminan, Tallinnan, Riian ja Vilnan kentät ennustepituuksittain

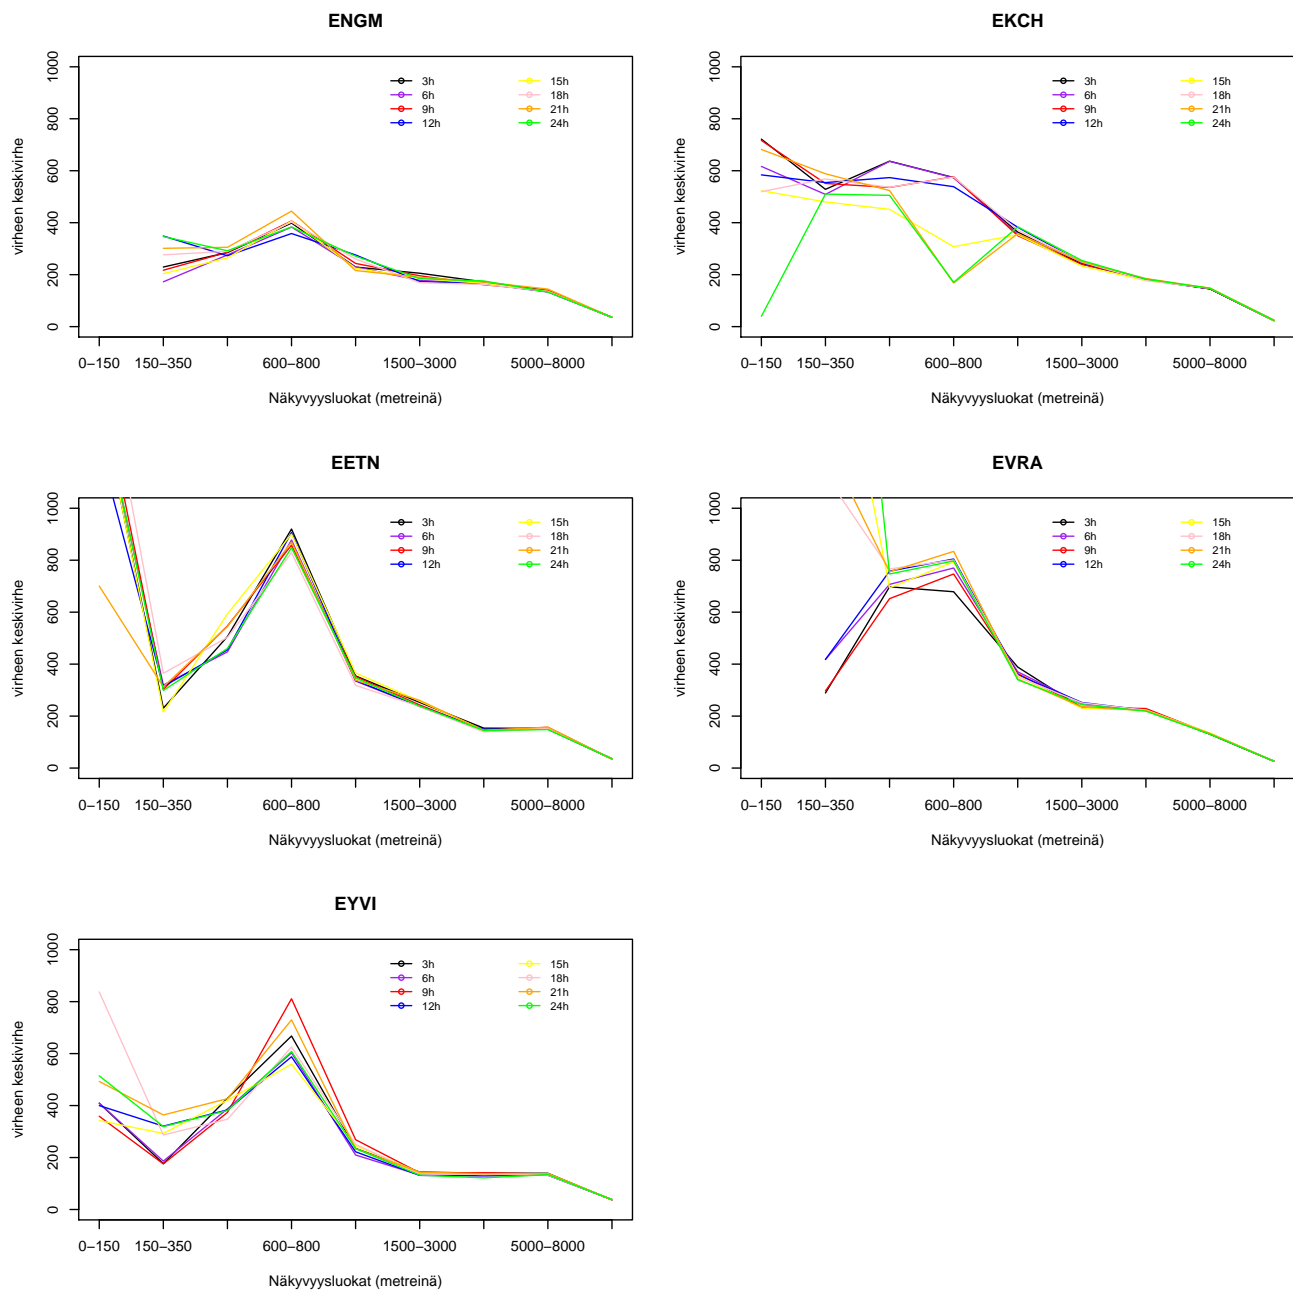
C Virheen keskivirhe eri ennustepituuksilla, Harmonie



Kuva C.1: Rovaniemen, Oulun, Kuopion ja Jyväskylän kentät ennustepituuksittain

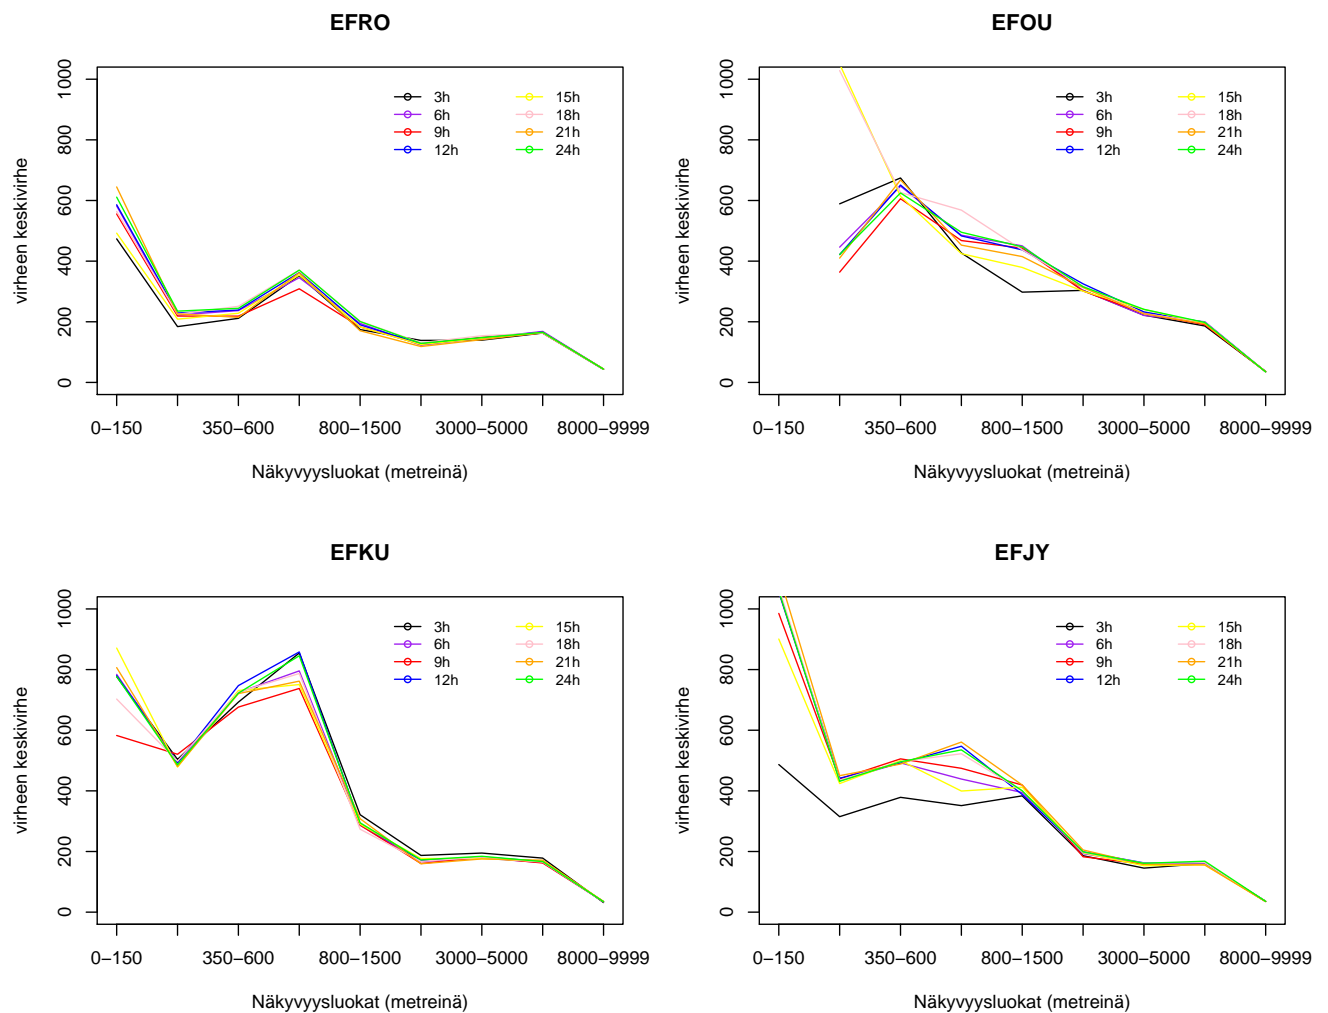


Kuva C.2: Tampereen, Helsinki-Vantaan, Lulea-Kallaxin ja Arlandan kentät ennustepi-tuuksittain

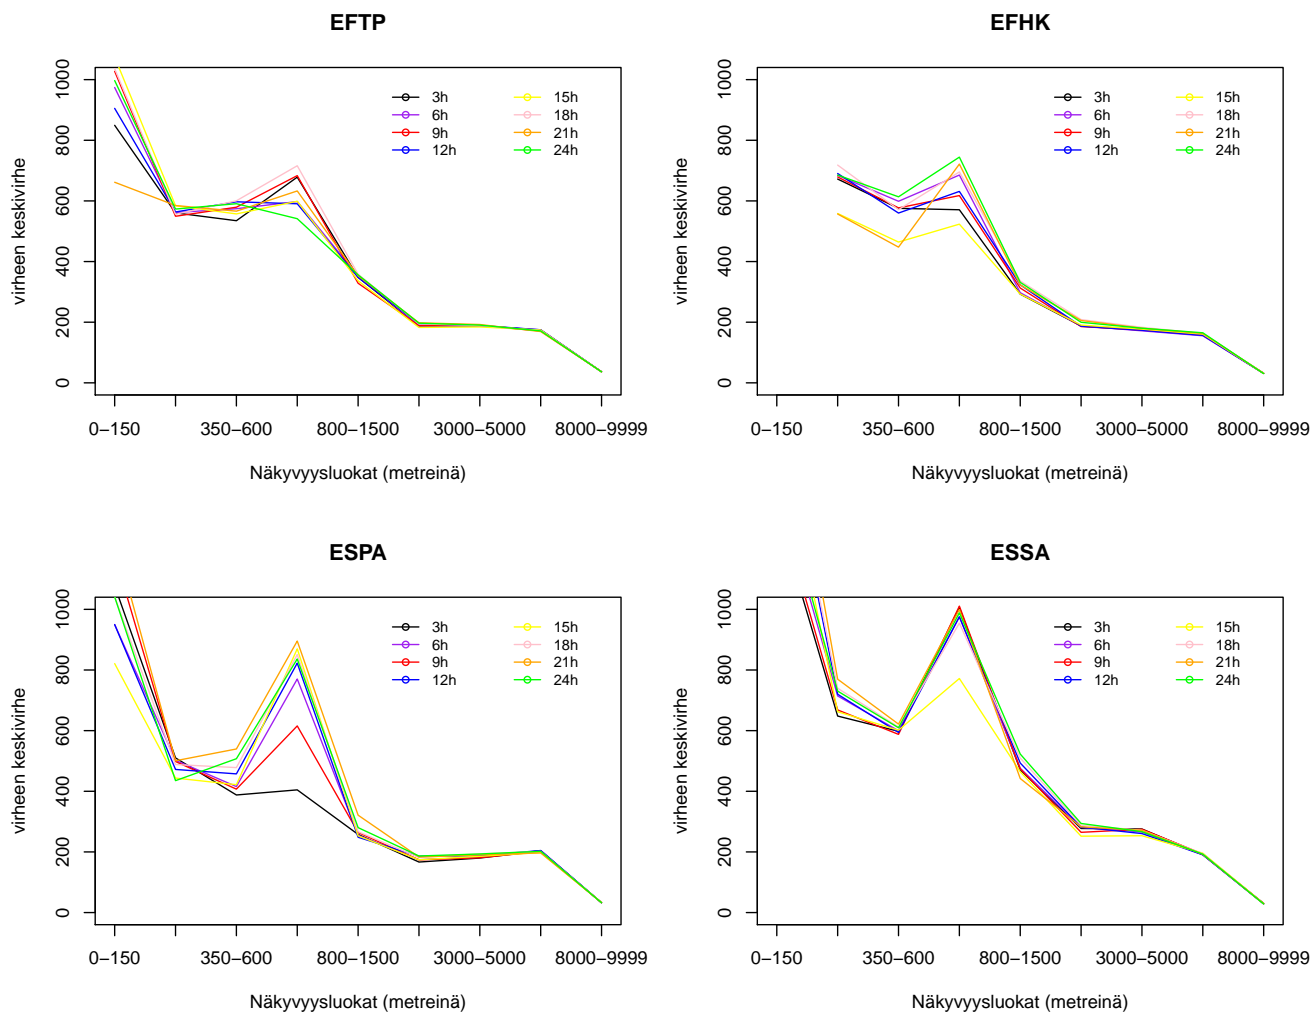


Kuva C.3: Oslon, Kööpenhaminan, Tallinnan, Riian ja Vilnan kentät ennustepituuksittain

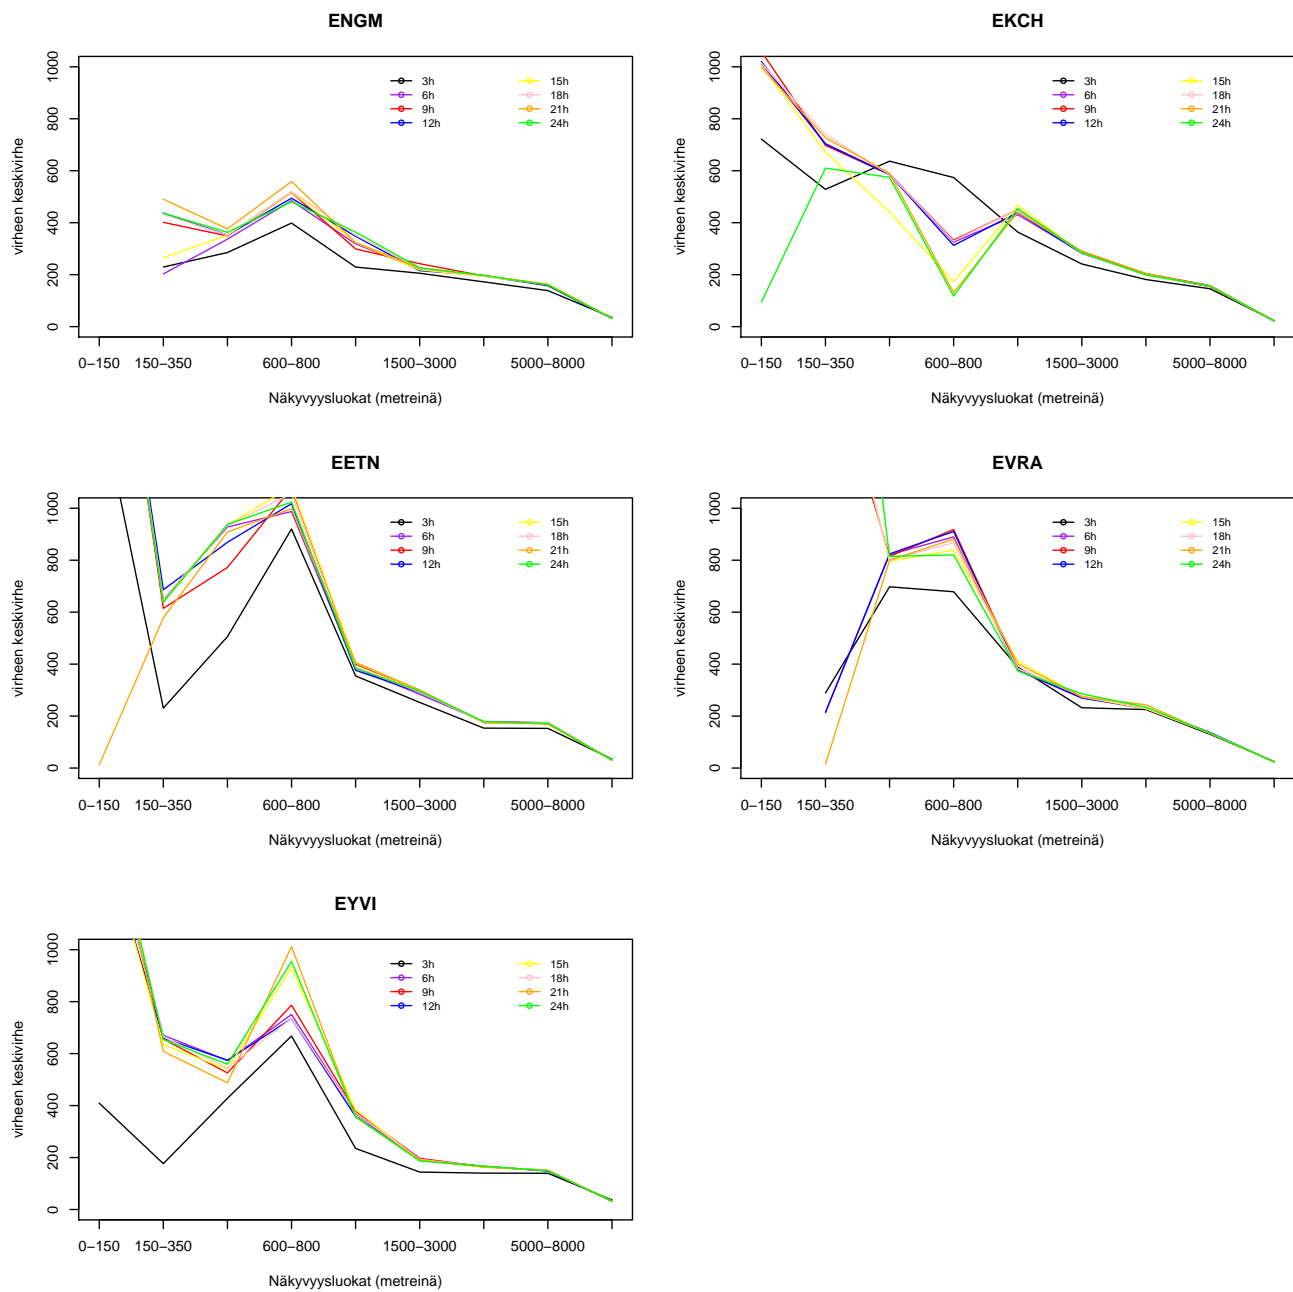
D Virheen keskivirhe eri ennustepituuksilla, fysikaalisesti postprosessoitu tuote



Kuva D.1: Rovaniemen, Oulun, Kuopion ja Jyväskylän kentät ennustepituuksittain

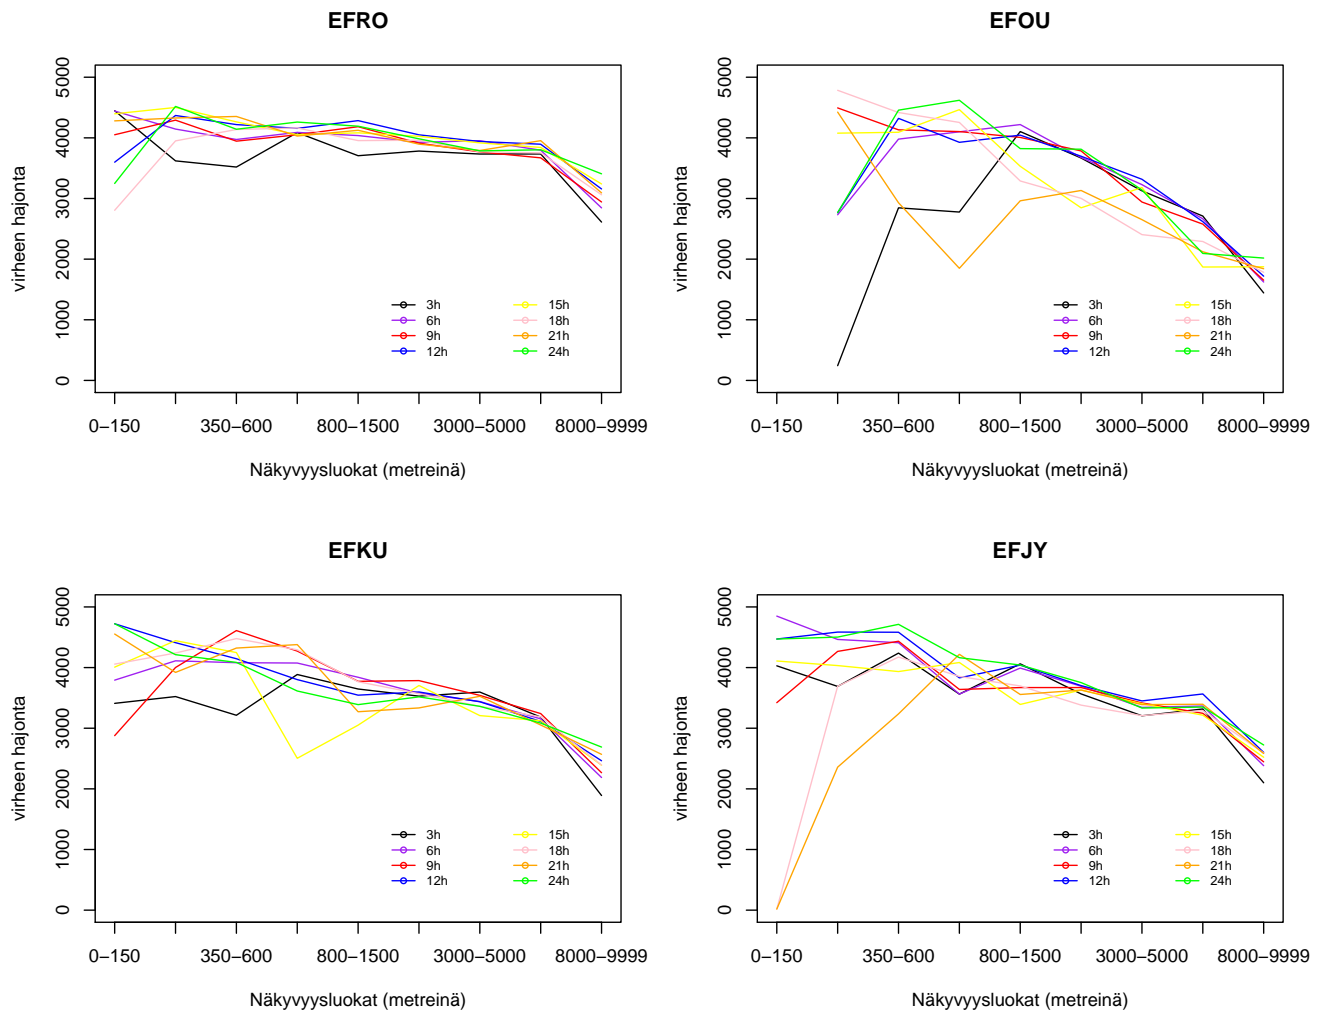


Kuva D.2: Tampereen, Helsinki-Vantaan, Lulea-Kallaxin ja Arlandan kentät ennustepi-tuuksittain

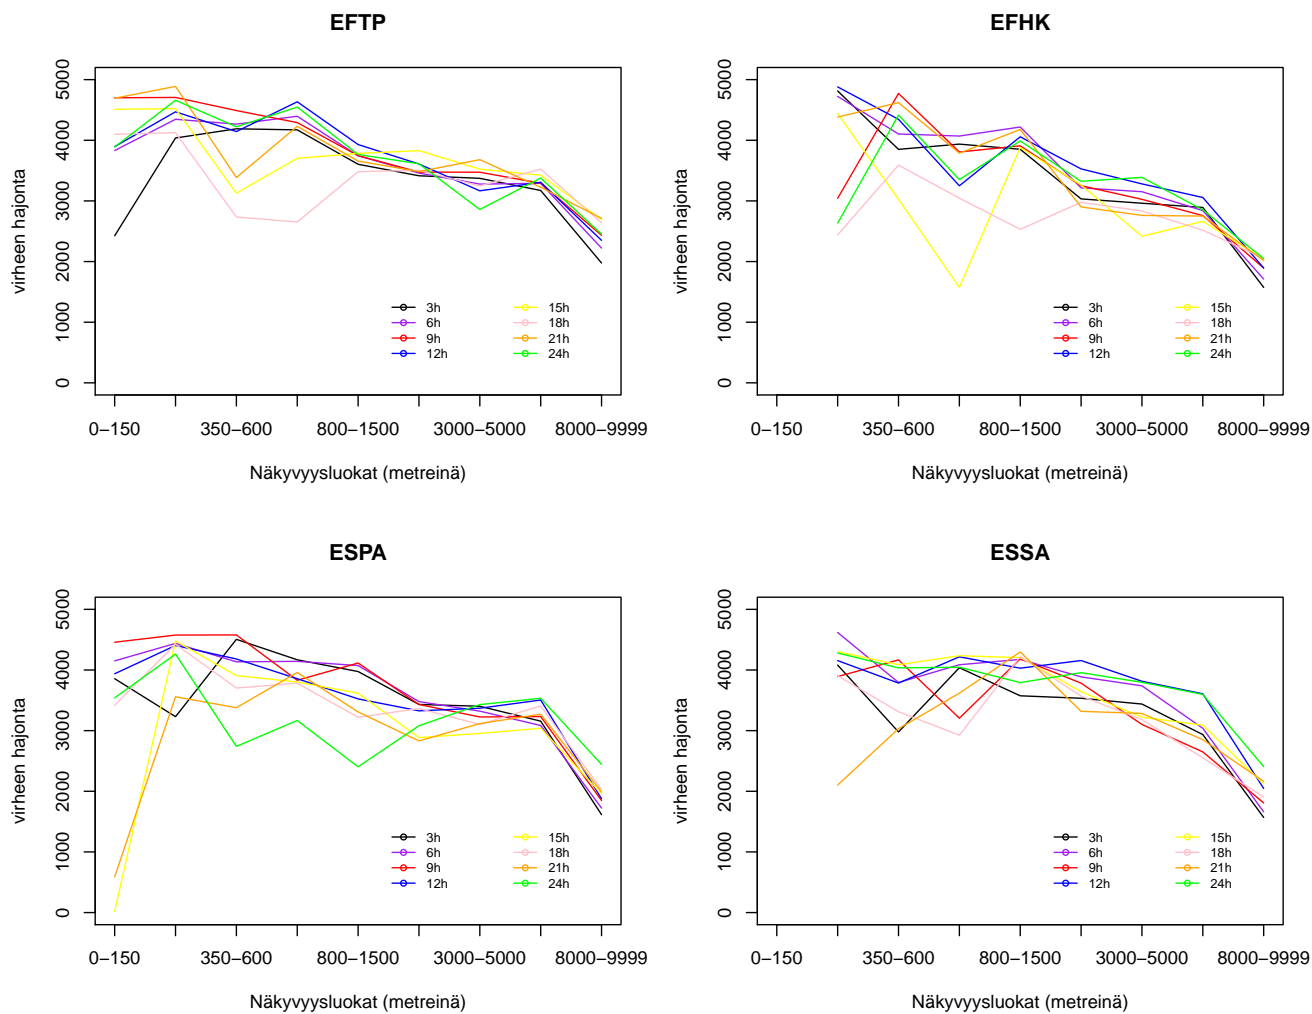


Kuva D.3: Oslon, Kööpenhaminan, Tallinnan, Riian ja Vilnan kentät ennustepituuksittain

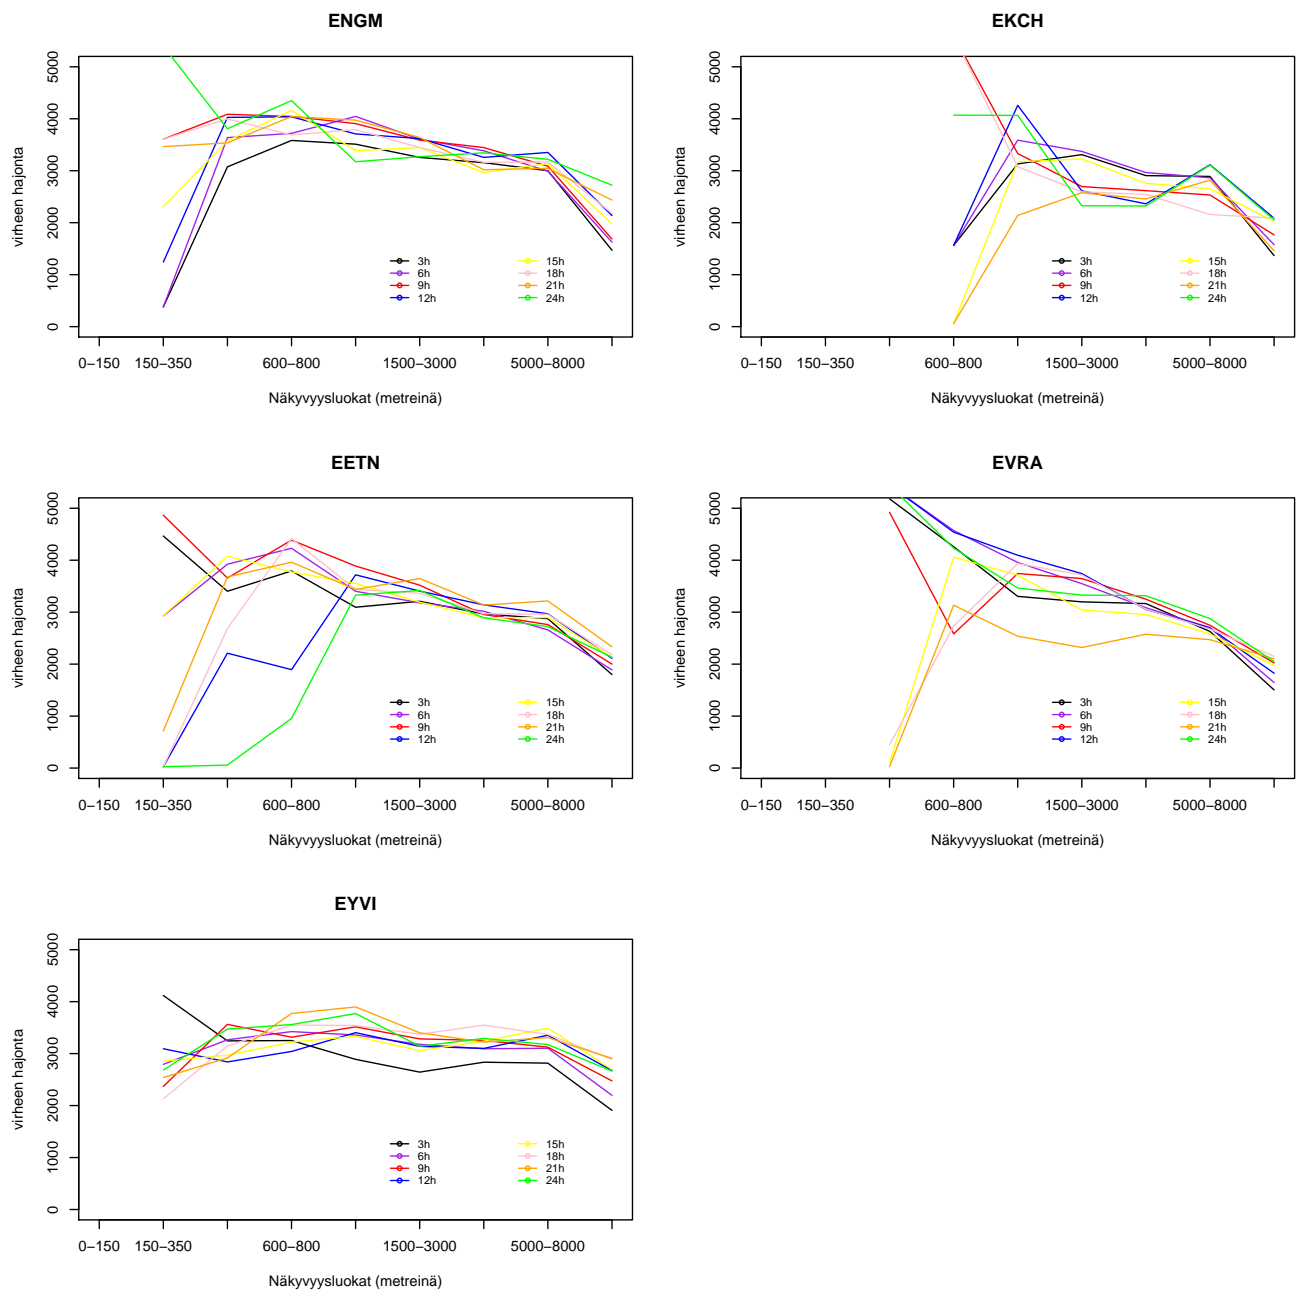
E Virheen keskihajonta eri ennustepituuksilla, analo- giaennusteet



Kuva E.1: Rovaniemen, Oulun, Kuopion ja Jyväskylän kentät ennustepituuksittain

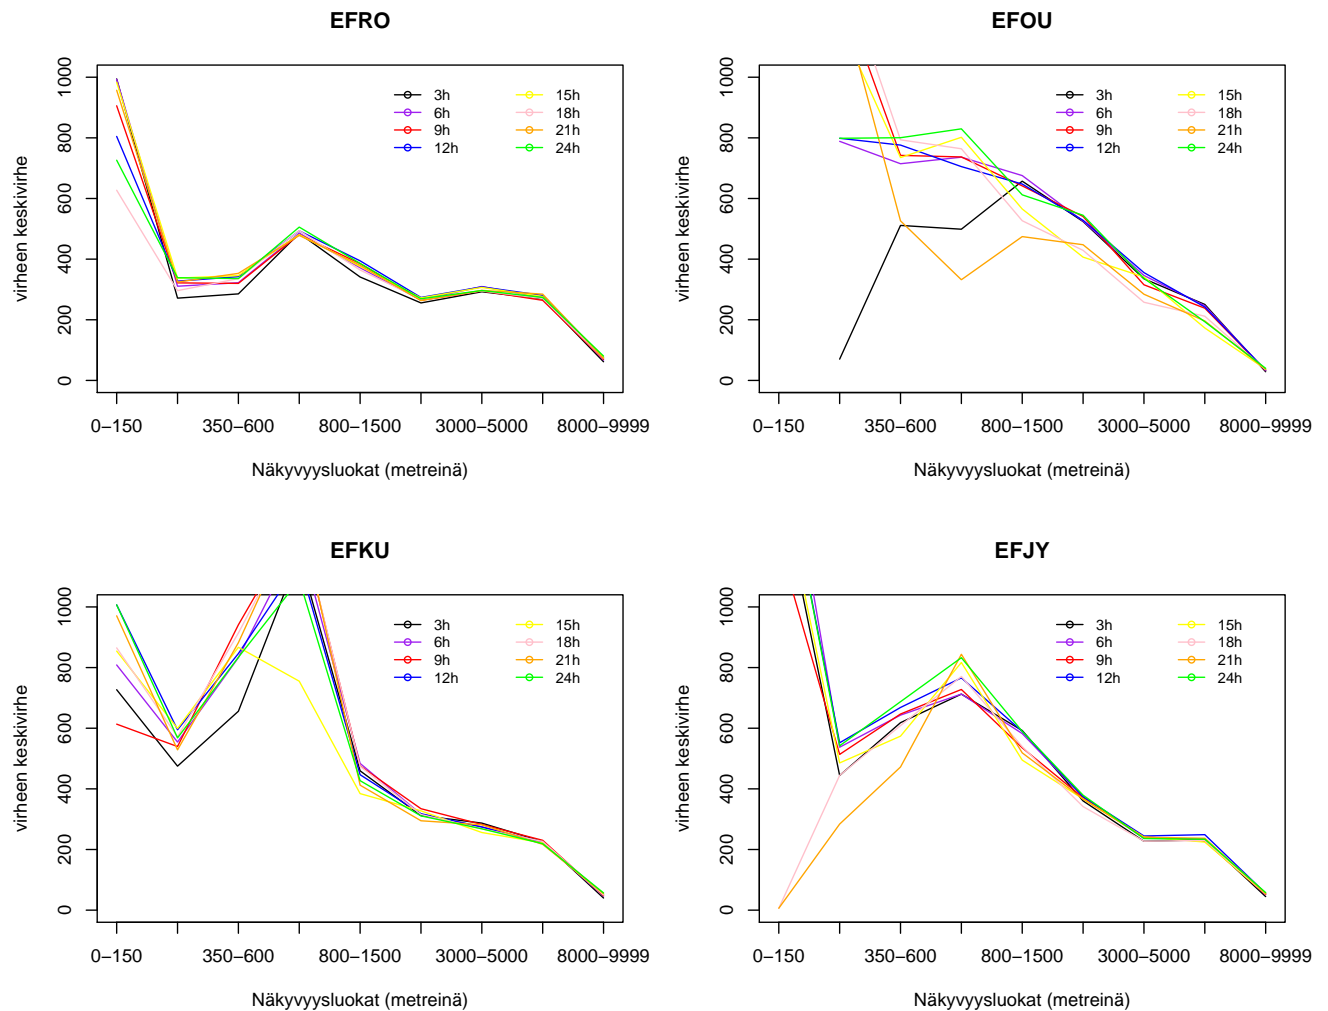


Kuva E.2: Tampereen, Helsinki-Vantaan, Lulea-Kallaxin ja Arlandan kentät ennustepi-
tuuksittain

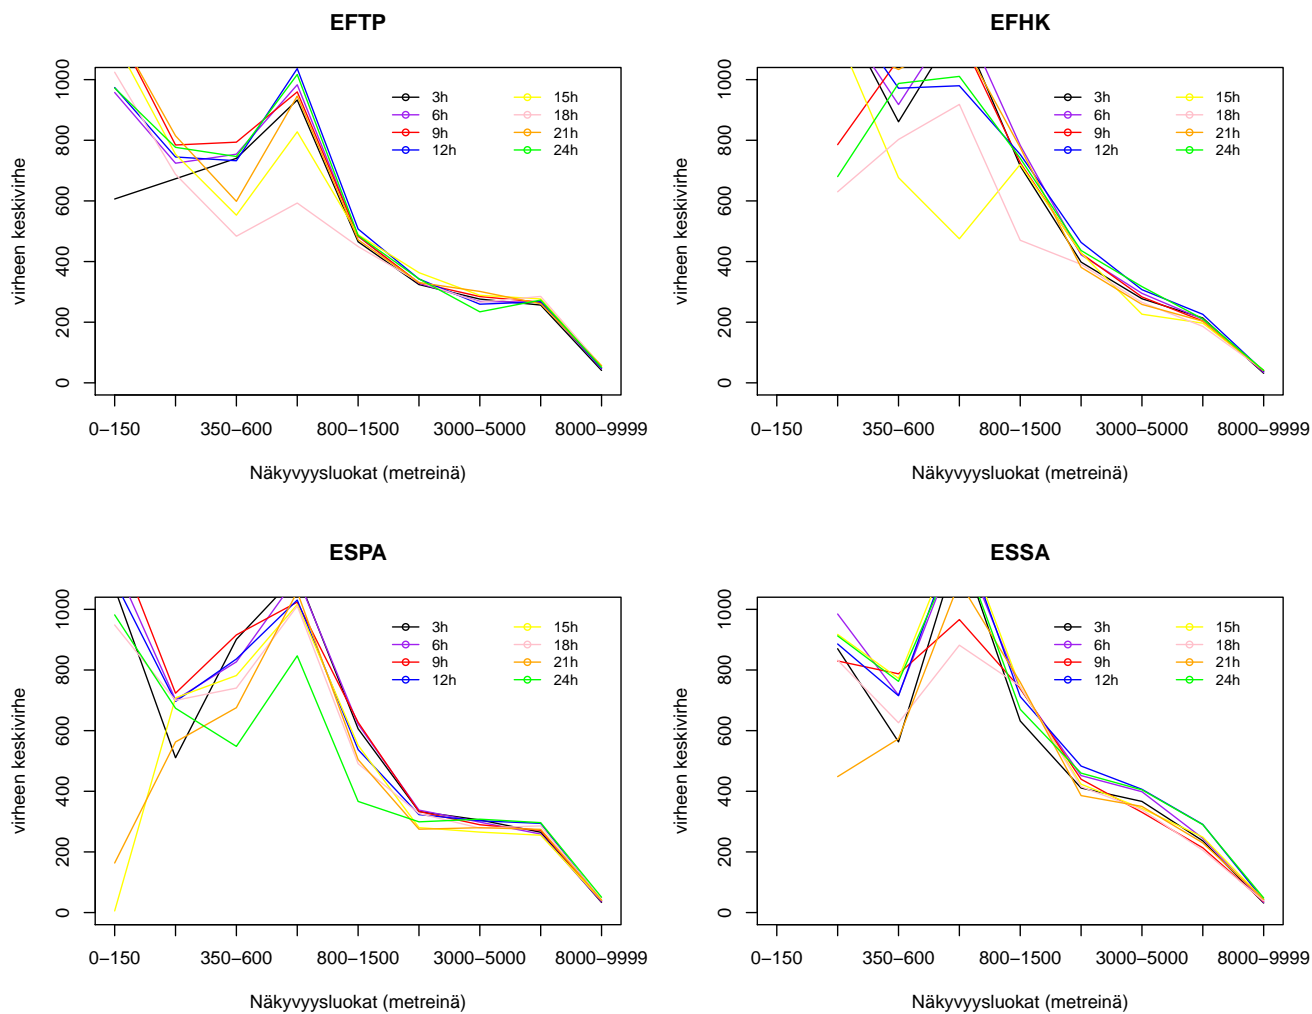


Kuva E.3: Oslon, Kööpenhaminan, Tallinnan, Riian ja Vilnan kentät ennustepituuksittain

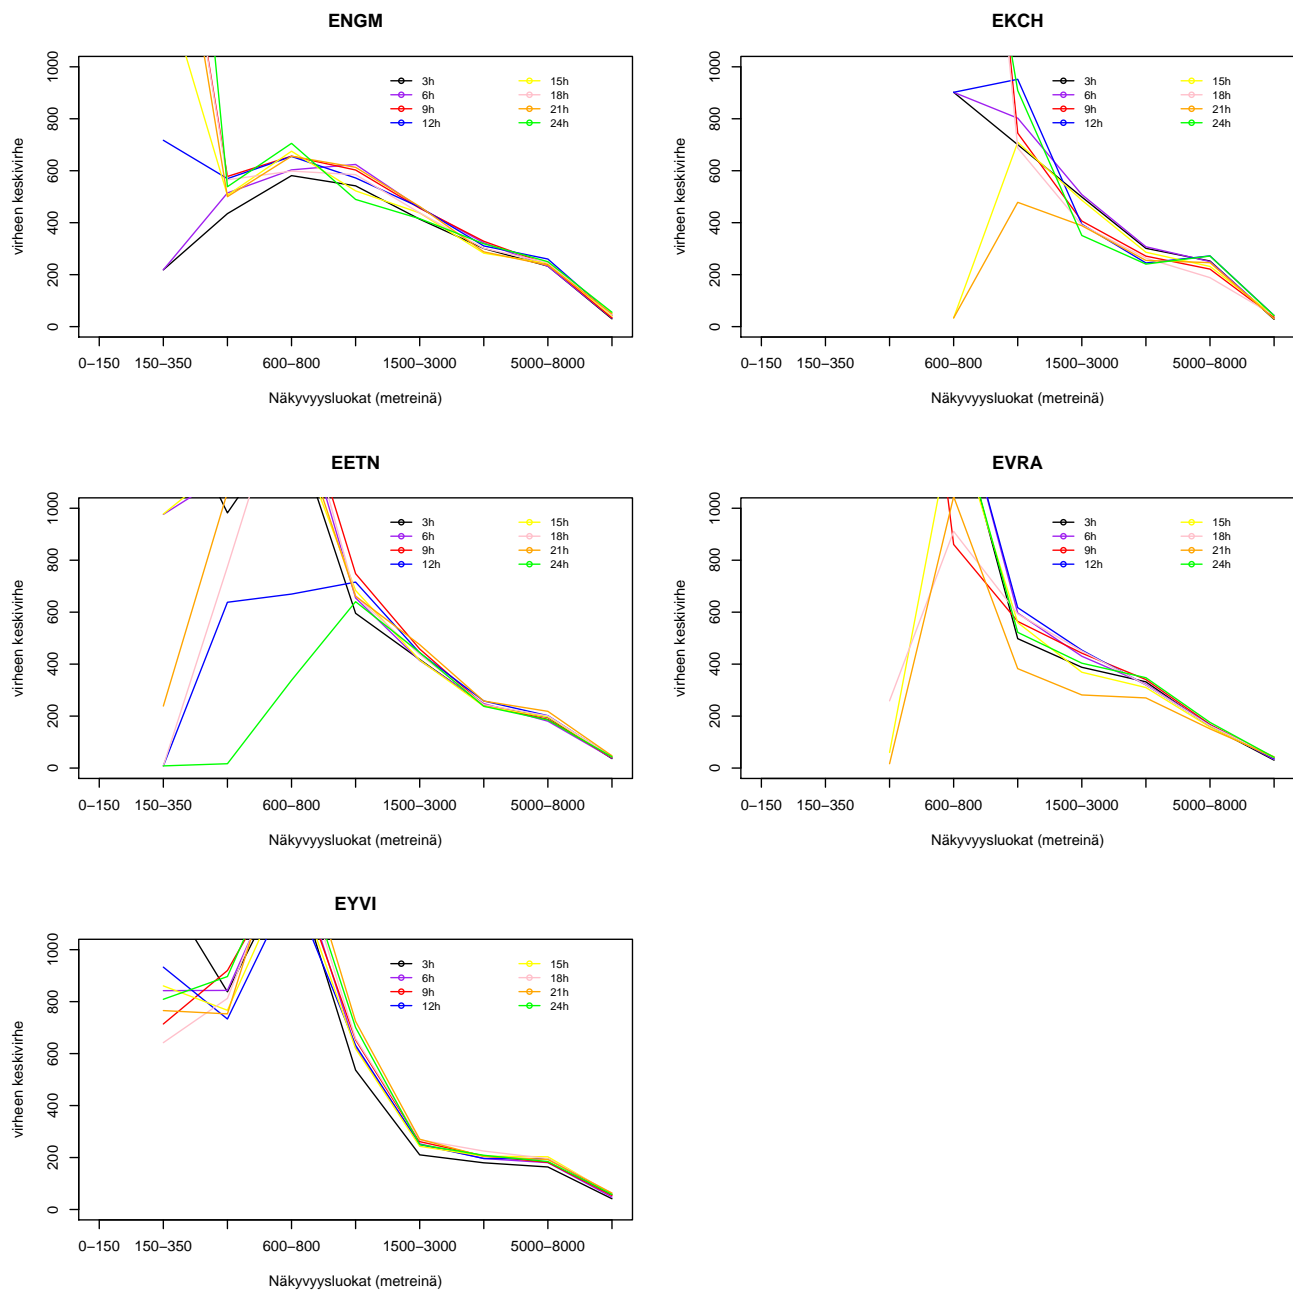
F Virheen keskivirhe eri ennustepituuksilla, analogiaennusteet



Kuva F.1: Rovaniemen, Oulun, Kuopion ja Jyväskylän kentät ennustepituuksittain



Kuva F.2: Tampereen, Helsinki-Vantaan, Lulea-Kallaxin ja Arlandan kentät ennustepituuksittain



Kuva F.3: Oslon, Kööpenhaminan, Tallinnan, Riian ja Vilnan kentät ennustepituuksittain